

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

DIPLOMSKI RAD

**DETERMINANTE KRETANJA DEVIZNOG
TEČAJA**

Mentor:

doc. dr. sc. Josip Visković

Student:

Kristina Žižić, univ. bacc. oec.

Split, kolovoz 2018.

SADRŽAJ:

1. UVOD	4
1.1. Problem i predmet istraživanja.....	4
1.2. Ciljevi i hipoteze istraživanja	6
1.3. Metode istraživanja	4
1.4. Doprinos istraživanja	9
1.5. Struktura diplomskog rada	10
2. POJAM, VRSTE I FORMIRANJE DEVIZNOG TEČAJA.....	11
2.1. Pojam i vrste deviznog tečaja	11
2.1.1. Definicija deviznog tečaja	11
2.1.2. Vrste deviznog tečaja.....	12
2.1.3. Devizno tržište	17
2.2. Važnost i značaj deviznog tečaja.....	18
2.3. Čimbenici formiranja deviznog tečaja	20
2.4. Teorije deviznih tečajeva	26
2.4.1. Teorija pariteta kupovnih moći - PPP teorija	26
2.4.2. Međunarodni Fisherov efekt - IFE	28
2.5. Tehnike predviđanja deviznog tečaja	31
3. KARAKTERISTIKE DRŽAVA ODABRANIH VALUTA.....	34
3.1. Sjedinjenje Američke Države.....	36
3.2. Euro zona	36
3.3. Velika Britanija	37
3.4. Japan.....	37
4. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA DETERMINANTI NA KRETANJE DEVIZNOG TEČAJA	39
4.1. Podaci i metodologija istraživanja	39

4.2. Utjecaj determinanti na kretanje tečaja USD/EUR	41
4.3. Utjecaj determinanti na kretanje tečaja USD/GBP	51
4.4. Utjecaj determinanti na kretanje tečaja USD/JPY	57
5. ZAKLJUČAK.....	65
SAŽETAK.....	78
SUMMARY.....	78
LITERATURA	67
POPIS GRAFIKONA, SLIKA I TABLICA.....	70
PRILOZI	72

1. UVOD

1.1. Problem i predmet istraživanja

Devizni tečaj je cijena jedne jedinice strane valute izražena brojem jedinica domaće valute. Tečaj se formira zavisno od tržišne ponude i potražnje, dnevnog prometa i promjena stranih valuta te se svakodnevno mijenja. Zbog učestalih fluktuacija razine tečaja i mnogih varijabli koje na isti utječu, pojam tečaja popraćen je s neizvjesnošću i svojevrsnim rizikom.¹

Devizni tečaj je vrlo važna varijabla koja je sveprisutna u cijeloj ekonomiji, odnosno gospodarstvu. Počnimo od pojedinca koji npr. podiže kredit s valutnom klauzulom. U slučaju deprecijacije domaće valute u odnosu na stranu pojedinac bi morao izdvojiti veću količinu novca za njegovu otplatu. Primjer su stambeni krediti vezani uz švicarski franak, pri čemu posljedice promjene tečaja snose građani koji su takve kredite uzeli. Nadalje, ako se promatra aktivnost multinacionalnih kompanija tada je kretanje deviznog tečaja iznimno bitno jer će utjecati na odluku kompanija o financiranju, investiranju, hedgingu² te odluci hoće li poduzeće reinvestirati ili remittirati sredstva tvrtke „kćeri“.

Važnost deviznog tečaja kao varijable ekonomske politike je višestruka. Promjena deviznog tečaja utječe na cijene, rentabilnost izvoza, ali i na domaće cijene izvoznih dobara. Na taj način promjena deviznog tečaja utječe na promjenu relativnih cijena, ali i na redistribuciju dohotka, relokaciju ekonomskih resursa i na tempo gospodarskog razvoja. Razina deviznog tečaja i njegova (ne)stabilnost danas se uzima kao pokazatelj gospodarske snage, stabilnosti i stanja gospodarstva.³

Kada bi svakodnevno s preciznošću mogli predvidjeti kretanje tečaja za sljedeći dan, sat, navedeni rizici nebi postojali. Kao glavne determinante utjecaja na devizni tečaj u teoriji navode se: promjena razlike domaće i inozemne inflacije, promjena razlike domaće i inozemne kamatne stope, promjena razlike između domaće i inozemne razine dohotka, promjena deviznih kontrola te promjena u očekivanjima buduće razine deviznih tečajeva. Postoje mnoga istraživanja i modeli koji nastoje otkriti što određuje kretanje deviznog tečaja u najvećoj mjeri. Autori navode razne determinante utjecaja na devizni tečaj, ali poteškoću predstavljaju varijable koje nije moguće kvantificirati (npr. političke odluke) te varijable koje su psihološke naravi.

¹Tečajna lista: Mijenjanje i predviđanje tečaja, [Internet], raspoloživo na : <http://www.tecajnalista.info/mijenjanje-i-predvidjanje-tecaja.htm>, [23.04.2018.]

²Poslovno-financijska strategija izbjegavanja ili umanjivanja nastupa rizika, tj. gubitka, kod jedne operacije, poduzimanjem druge operacije.

³Lovrinović, I. (2015): Globalne financije, ACCENT, Zagreb, str 83., 84.

Clostermann i Schnatz (2000.), proveli su istraživanje utjecaja determinanti na tečaj USD/EUR u razdoblju od 1975. do 1998. godine na bazi kvartalnih podataka. Autori su pri tom formirali vlastiti „synthetic euro exchange rate“, kao geometrijski ponderiranu sredinu tečaja dolara prema pojedinim EMU valutama (njemačka marka 37,4%, francuski franak 18,4%, talijanska lira 14,2% , itd.) Modelom korekcije pogreške, eng. SEECM (Single equation error correction model) došli su do sljedećih zaključaka: trajni porast cijene u odnosu između eng. traded and non-traded goods u Eurozoni i Sjedinjenim Američkim Državama ima pozitivan utjecaj na realni sintetički tečaj eura, razlike u kamatnim stopama⁴ imaju značajan i pozitivan utjecaj na tečaj eura dok negativan utjecaj (deprecijacija) na tečaj eura ima porast cijene nafte. Također, autori navode da osim fundamentalnih determinanti na tečaj eura pozitivno utječu i prošla kretanja tečaja eura.

Urrutia, Lynch, Olfindo, Tampis (2015.), koristili su STEPWISE Višestruku linearnu regresiju kako bi identificirali utjecaj sljedećih 5 determinanti na tečaj Filipina: kamatna stopa, inflacija, uvoz, izvoz i omjer radne snage naspram radno sposobnog stanovništva (eng. LabourForceParticipation Rate). Značajnim i pozitivnim varijablama utjecaja pokazale su se kamatna stopa i omjer radne snage naspram radno sposobnog stanovništva.

Ramasamy i Abar (2015.), istraživali su utjecaj niza odabranih nezavisnih varijabli na kretanje tri valutna para (AUD/USD, USD/EUR, AUD/EUR) koristeći bootstrapping tehniku, kako bi mogli provesti regresijski model. Istraživanje je provedeno na temelju godišnjih podataka, koji su prikupljeni u razdoblju od 10 godina. Autori su promatrali utjecaj sljedećih varijabli: kamatna stopa, inflacija, platna bilanca, stopa zaposlenosti, korupcija, BDP, proračunski deficit/suficit, relativna porezna stopa i stopa zaduživanja države. Od navedenih varijabli neznačajnim pokazale su se proračunski deficit i stopa zaposlenosti. Također zanimljivo je da mnoge varijable; kamatna stopa, platna bilanca i inflacija, koje teorijski trebaju imati pozitivan utjecaj na devizni tečaj pokazale su negativan predznak, koji autori djelom objašnjavaju kao utjecaj psiholoških čimbenika.

Ovaj rad bavi se problematikom definiranja determinanti koje utječu na kretanje, odnosno formiranje deviznog tečaja, s posebnim naglaskom na kretanje deviznih tečajeva najjačih svjetskih valuta, odnosno najvažnije svjetske valute – USD prema drugim svjetskim valutama (EUR, JPY, GBP). Za navedene valute možemo reći da su svjetske jer su osim u

⁴Razlika između dugoročnih kamatnih stopa državnih obveznica među zemljama, jer se utjecaj kratkoročnih kamatnih stopa u istraživanjima pokazao kao manje značajan (Clostermann, Schantz 2000. str 9.).

nacionalnim okvirima, široko prihvaćene u svijetu za podmirenje inozemnih transakcija te su zamjenjive za mnoge druge valute.⁵

Iz definiranog problema istraživanja proizlazi i predmet istraživanja. Dakle, predmet ovog istraživanja je analiza utjecaja determinanti na kretanje tečaja parova najvažnijih svjetskih valuta u razdoblju od 2002. do 2017. godine. Navedeno razdoblje odabrano je s početkom u 2002. godini iz razloga što su 1. siječnja 2002. godine novčanice i kovanice eura puštene su u optjecaj, dok je potpuna zamjena nacionalnih valuta obavljena krajem veljače 2002. godine.⁶ U istraživanju će se kao domaća valuta u svim parovima promatrati američki dolar (USD), a valutni parovi koji će se u radu analizirati su USD/EUR, USD/GBP i USD/JPY. Dakle, na primjeru tečaja američkog dolara analizirat će se determinante deviznog tečaja. Kao determinante utjecaja promatrat će se sljedeće varijable na temelju mjesečnih podataka: promjena razlike između domaće i inozemne inflacije, domaće i inozemne kamatne stope, domaće i inozemne razine dohotka (mjerene indeksom industrijske proizvodnje⁷), VIX⁸ indeks rizičnosti, kretanje cijene nafte (WTI) te Consumer Confidence Index (CCI).

1.2. Ciljevi i hipoteze istraživanja

S teorijskog stajališta, cilj je definirati devizni tečaj i pojmove koje se uz njega vežu, objasniti važnost promjene kretanja tečaja u svijetu, te objasniti kako se devizni tečaj formira. Također, cilj je prezentirati vezu između kretanja deviznog tečaja i pojedine varijable koje na isti utječu.

S empirijskog stajališta, cilj ovog rada je utvrditi postoji li značajan utjecaj pojedine determinante na kretanje tečaja odabranih valutnih parova (USD/EUR, USD/GBP te USD/JPY) u promatranom razdoblju.

Hipoteze koja će se ovim istraživanjem provjeravati su sljedeće:

H1: Determinante koje statistički značajno pozitivno utječu na kretanje tečaja američkog dolara su kamatne stope, razina dohotka, indeks potrošačkog optimizma, percepcija rizika investitora i cijena nafte.

H2: Determinante koje statistički značajno negativno utječu na kretanje tečaja američkog dolara su stopa inflacije, razina dohotka i cijena nafte.

⁵Lovrinović, I. (2015): op.cit. str. 90.

⁶Wikipedia: Euro, [Internet], raspoloživo na :<https://hr.wikipedia.org/wiki/Euro>, [23.04.2018.]

⁷U daljnjem tekstu IIP

⁸Indeksom VIX mjeri se implicitna kolebljivost cijena opcija na dionički indeks S&P 500 i u literaturi se često koristi kao pokazatelj nesklonosti ulagača riziku.

Kao prva determinanta utjecaja na kretanje deviznog tečaja koristit će se razlika u kamatnim stopa među promatranim zemljama, respektivno za dvije promatrane zemlje. Kamatna stopa utječe na kretanje investicija u svijetu, što utječe na ponudu i potražnju za određenom devizom te u konačnici i na samo kretanje deviznog tečaja. Ako kamatna stopa u SAD-u poraste, dok u drugoj promatranoj zemlji ostane ista ili na manjoj razini, američki investitori će smanjiti potražnju za stranom valutom⁹. Istodobno, će rast kamatnjaka u SAD-u motivirati strane investitore da višak novca ulažu u SAD pa će se povećati ponuda strane valute i istodobno povećati potražnja za domaćom valutom (USD). Dakle tečaj eura će padati, odnosno tečaj domaće valute - dolara će aprecirati. Stoga se očekuje pozitivno djelovanje kamatne stopa na tečaj dolara (u istom smjeru).

Nadalje, kroz međunarodnu razmjenu na ponudu i potražnju za tečajem i na samo kretanje tečaja utječe i razlika u stopama inflacije između promatranih zemalja. Primjerice, ako stopa inflacije znatno poraste u SAD-u, dok u stranoj državi (Japan, Euro zona i Velika Britanija) ostane ne promijenjena ili na manjoj razini, tada američka roba postaje skuplja za inozemne kupce, a američki kupci počinju više kupovati robu iz inozemstva. Na deviznom tržištu povećava se potražnja za inozemnom valutom (radi financiranja uvoza), dok se ponuda strane valute prema dolaru smanjuje (radi destimuliranja izvoza iz SAD-a). Navedene promjene ponude i potražnje dovode do rasta vrijednosti eura, odnosno deprecijacije domaće valute. Dakle, očekuje se negativno djelovanje inflacije na domaću valutu, odnosno tečaj dolara (u suprotnom smjeru).

Kao treća varijabla utjecaja u literaturi spominje se razlika između domaće i inozemne razine dohotka. Ako dođe do porasta razine dohotka u SAD-u, dok u drugoj promatranoj državi razina dohotka ostane nepromijenjena, potražnja za inozemnim dobrima će rasti što će dovesti do promjene tečaja strane valute na način da će tečaj strane valute aprecirati, odnosno domaće valute oslabiti. Umjesto, podataka o rastu BDP-a u radu će se koristiti njegova proxy varijabla Indeks industrijske proizvodnje (IIP)¹⁰. Dakle, očekuje se negativan utjecaj na tečaj dolara (u suprotnom smjeru). Također, ova varijabla može imati i pozitivan utjecaj na tečaj domaće valute. Naime, promjena razine dohotka može preko kamatne stope indirektno djelovati na tečaj. Porast razine dohotka, odnosno rasta gospodarstva može biti naznaka rasta kamatnih stopa u budućnosti, što može rezultirati rastom vrijednosti domaće valute

⁹Napomena: kao strane valute koriste se japanski jen, britanska funta i euro.

¹⁰ IIP je izabran jer se podaci i ovom indeksu objavljuju mjesečno, dok podatke o promjenama BDP-a postoje samo na vartalnoj razini.

(aprecijacija dolara). Dakle, IIP indirektno može imati i pozitivan utjecaj na tečaj domaće valute - dolara.

Četvrta varijabla predstavljena je VIX indeksom, koji se u literaturi još naziva „indeksom straha“. Indeks računa i objavljuje Chicago Board Options Exchange (CBOE). VIX indeksom mjeri se implicitna kolebljivost cijena opcija na dionički indeks S&P 500 i često se koristi kao pokazatelj nesklonosti ulagača riziku. Dakle, što je vrijednost ovog indeksa veća, veća je i averzija investitora prema riziku, što znači da će investitori prodavati rizične dionice i obveznice, a ulagati odnosno kupovati vrijednosnice američke vlade („sigurna investicija“). Navedeno bi trebalo dovesti do aprecijacije dolara. Dakle, može se očekivati da će utjecaj ovog indeksa na tečaj dolara biti pozitivan (u istom smjeru).

Consumer Confidence Index (CCI) mjeri količinu optimizma, odnosno pesimizma koji se veže za stanje gospodarstva neke države. Može se reći da mjeri kako se razvija potrošačka klima u nekoj državi, kako potrošači percipiraju trenutnu poslovnu klimu, mogućnosti zapošljavanja, odnosno percipiraju li potrošači državu kao rizičnu ili ne. Također, CCI predstavlja vodeći indikator stanja gospodarstva države. Iz navedenog slijedi da bi porast CCI-a trebao odražavati pozitivnu klimu države, odnosno veću potrošnju, te samim time valuta te države trebala bi aprecirati. Dakle, ako CCI poraste u SAD-u više nego u drugim državama ili pak u njima ostane nepromijenjen ili se smanji, trebalo bi doći do aprecijacije tečaja dolara jer investitori imaju veće povjerenje u SAD, odnosno dolar (u istom smjeru).

Zadnja, no ne i manje bitna varijabla utjecaja je kretanje cijene nafte preko WTI¹¹ Crude Oil Price. Smatra se da sam utjecaj kretanja cijene nafte na tečaj valute uvjetovan zavisnošću promatranih zemalja o uvozu nafte. Clostermann i Schnatz (2000.) naglašavaju da trajni rast cijene nafte doprinosi inozemnoj konkurenciji onih zemalja koje manje zavise o uvozu nafte. Također navode da potrošnja nafte relativno prema ekonomskoj aktivnosti nije toliko važna koliko sama zavisnost države o uvozu nafte (za zadovoljenje potreba). Dakle, rast cijene nafte bi trebao pozitivno utjecati na tečaj dolara (aprecijacija) onda kada je druga promatrana država više ovisna o uvozu nafte nego SAD (u istom smjeru). Dok kod veće zavisnosti SAD-a o uvozu nafte nego li druge promatrane države, pri rastu cijene nafte trebalo bi doći do deprecijacije dolara u odnosu na drugu valutu (u suprotnom smjeru).

¹¹ WTI - West Texas Intermediate

1.3. Metode istraživanja

U teorijskom dijelu rada koristit će se različite znanstvene metode:

Deduktivna metoda, kojom se „iz općih stavova izvode posebni, pojedinačni, iz općih postavki dolazi se do konkretnih pojedinačnih zaključaka, iz jedne ili više tvrdnji izvodi se neka nova tvrdnja koja proizlazi iz prethodnih tvrdnji.“ **Induktivna metoda**, kojom se, na temelju pojedinačnih činjenica i saznanja, dolazi do uopćavanja i formiranja zakonitosti, odnosno spoznaje novih činjenica i novih zakonitosti. **Metoda analize** je „postupak znanstvenog istraživanja i objašnjenja stvarnosti putem raščlanjivanja složenih misaonih tvorevina (pojmova, sudova i zaključaka) na njihove jednostavnije sastavne dijelove i elemente i izučavanje svakog dijela (i elementa) za sebe i u odnosu na druge dijelove, odnosno cjeline.“ **Metoda sinteze**, s druge strane, istražuje i objašnjava stvarnost putem spajanja, sastavljanja jednostavnih misaonih tvorevina u složene i složenijih u još složenije, povezujući izdvojene elemente, pojave, procese i odnose u jedinstvenu cjelinu u kojoj su njezini dijelovi uzajamno povezani.¹² Nadalje, koristit će se i **metoda deskripcije** pomoću koje se opisuju logike uzročnih veza između promatranih varijabli.

U empirijskom dijelu rada koristit će se **statistička metoda višestruke regresije** pomoću koje se objašnjava utjecaj dvije ili više nezavisnih varijabli (odabrane determinante kretanja tečaja) na zavisnu varijablu (kretanje tečaja). Dakle, pomoću višestruke regresije nastojat će se pokazati objašnjava li kretanje nezavisnih varijabli značajni dio promjene zavisne varijable u određenom periodu. Također, u ovom radu koristit će se **grafičko prikazivanje** radi vizualnog prikaza povezanosti između varijabli.

1.4. Doprinos istraživanja

Rijetkost je da je neka ekonomska kategorija toliko prisutna u svakodnevnim raspravama, u stručnoj, ali i najširoj javnosti kao devizni tečaj.¹³ Upravo je sama važnost deviznog tečaja poticaj ovog istraživanja.

Doprinos ovog istraživanja ogleda se u činjenici da će se promatrati kretanje deviznih tečajeva najvažnijih svjetskih valuta za koje se može reći da imaju ulogu svjetskog novca, odnosno analizirat će se determinante američkog dolara u odnosu na druge svjetske valute (EUR, GBP i JPY). Nadalje, istražiti će se utjecaj temeljnih teorijskih determinanti (kamatna

¹²Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, Ekonomski fakultet Rijeka, str. 323., 325., 327., 329-330.

¹³Lovrinović, I. (2015): op.cit. str. 83.

stopa, inflacija te BDP kroz IIP) zajedno s novim neistraženim varijablama (CCI i VIX indeks). Također, bit će korisno provjeriti postoji li uistinu povezanost između kretanja kamatne stope, inflacije i IIP s kretanjem tečaja i utječe li ta veza značajno na kreiranje deviznog tečaja. Clostermann i Schnatz (2000.) sugeriraju pozitivnu i značajnu vezu između kretanja cijene nafte i tečaja pa će se provjeriti vrijedi li uistinu ta veza za sve odabrane valutne parove. Novitet u istraživanju utjecaja na kretanje deviznog tečaja u ovom radu predstavljaju CCI i VIX indeks. Na temelju definicije navedenih varijabli, odnosno onoga što predstavljaju, može se pretpostaviti kako bi trebale djelovati na kretanje tečaja pa će se isto pokušati dokazati u empirijskom dijelu istraživanja.

1.5. Struktura diplomskog rada

Rad će osim standardnih dijelova, uvoda i zaključka, sadržavati još tri poglavlja.

U prvom, uvodnom poglavlju, definirat će se problem, predmet i cilj istraživanja. Također, elaborirat će se istraživačke hipoteze te navesti znanstvene metode koje će se koristiti u istraživanju. Na kraju prvog dijela bit će prezentiran opis strukture diplomskog rada.

U drugom dijelu, definirat će se pojam deviznog tečaja, prezentirati vrste tečaja te objasniti pojam deviznog tržišta. Nadalje, objasniti će se važnost i značaj deviznog tečaja kroz različite gospodarske aspekte. Također, će se predstaviti temeljni makroekonomski modeli određivanja deviznog tečaja kao i teorije predviđanja deviznog tečaja. Drugi dio će se zaključiti objašnjavanjem teorijske veze između pojedinih determinanti deviznog tečaja i samog tečaja.

U sljedećem, trećem poglavlju objasniti će se zašto su u istraživanje uzeti navedeni valutni parovi. Definirat će se pojam svjetskog novca i njegovo značenje. Također, prezentirati će se određene makroekonomske karakteristike odabranih zemalja.

Empirijski dio rada činit će četvrto poglavlje, u kojem će se testirati hipoteza o pozitivnom, odnosno negativnom utjecaju pojedinih determinanti za svaki odabrani valutni par zasebno. Pri tome će se definirati podaci, metodologija istraživanja te iznijeti rezultati statističke analize.

Zaključak, ujedno i posljednje poglavlje dat će pregled dobivenih rezultata, te ukazati na (ne)podudaranje teorijskih spoznaja i empirijskih dokaza. Dakle, usporedit će se dobiveni s očekivanim rezultatima. Rad će se završiti popisom literature, grafikona, tablica, slika te sažetkom na hrvatskom i engleskom jeziku.

2. POJAM, VRSTE I FORMIRANJE DEVIZNOG TEČAJA

2.1. Pojam i vrste deviznog tečaja

2.1.1. Definicija deviznog tečaja

Devizni tečaj predstavlja cijenu jedne jedinice strane valute izraženu brojem jedinica domaće valute. Dakle, devizni tečaj pokazuje koliko je jedinica domaćeg novca potrebno izdvojiti za jednu jedinicu stranog novca. Ovakva definicija ujedno predstavlja i direktan način kotiranja deviznog tečaja. Indirektno kotiranje pokazuje koliko jedinica strane valute treba platiti za jednu jedinicu domaće valute. Ovakvu vrstu kotiranja koristi manji broj zemalja, a među njima ističe se Velika Britanija.

Ovakve definicije tako izražavaju i karakterističnost koju ima strani novac u odnosu na domaći novac, gdje domaći novac na domaćem tržištu predstavlja samo mjeru vrijednosti ili mjerilo cijena kojim se izražava cijena određene robe. To znači da domaći novac na domaćem tržištu nije roba, dok je strani novac na domaćem tržištu roba kao svaka druga, a devizni tečaj zapravo predstavlja njegovu cijenu.¹⁴

Potrebno je razlikovati pojmove valuta i deviza. Valuta predstavlja novčanu jedinicu, zakonsko sredstvo plaćanja koje vrijedi samo na teritoriju zemlje koja je izdala tu valutu. Izvan tog područja valuta gubi svojstvo plaćanja u zakonodavnom smislu, bez obzira na svoju kupovnu moć. Dakle, kupovna moć određenog novca (valute) ne može na stranom tržištu, odnosno u drugom valutnom području doći do izražaja. S druge strane, deviza je potraživanje prema inozemstvu nastalo na temelju izvoza robe ili usluge. Deviza kao i svako drugo potraživanje nije, dakle, domaći novac odnosno valuta. Vlasnik deviza može ih prodati na domaćem ili inozemnom tržištu po odgovarajućem deviznom tečaju. Deviznim tečajem ostvaruje se veza između nacionalnih valuta i tržišta te upravo posredovanjem deviznog tečaja kupovna moć domaćeg novca u inozemstvu dolazi do izražaja.¹⁵

Kako bi se daljnja poglavlja mogla što lakše razumjeti kratko će se objasniti dva pojma usko vezana uz promjenu deviznog tečaja, odnosno cijene strane valute koja se mijenja svakog trenutka. U slučaju da ponuda i potražnja određuju veličinu tečaja te promjene nazivaju se aprecijacija odnosno deprecijacija, s druge strane ako država određuje veličinu tečaja te se promjene nazivaju revalvacija i devalvacija. Aprecijacija (revalvacija) predstavlja

¹⁴Fortrade: Edukacija – devizni tečaj, [Internet], raspoloživo na : <https://www.fortrade.eu/edukacija/clanci/valutni-derivati/devizni-tecaj/>, [10.07.2018.]

¹⁵Lovrinović, I. (2015): op.cit., str. 84.

povećanje vrijednosti domaće valute koje se očituje u smanjenju broja jedinica domaće valute koje je potrebno izdvojiti za kupnju jedne jedinice strane valute (jačanje domaće valute). Deprecijacija (devalvacija) je smanjenje vrijednosti domaće valute koje se očituje u povećanju broja jedinica domaće valute koje je potrebno izdvojiti za jednu jedinicu strane valute.

2.1.2. Vrste deviznog tečaja

Za potrebe ovog rada u ovom poglavlju bit će pojašnjene dvije podjele deviznog tečaja. Prva kategorija dijeli devizni tečaj na nominalni, realni i efektivni dok se druga podjela odnosi na vrstu sustava deviznog tečaja (fiksni i fluktuirajući).

Nominalni devizni tečaj predstavlja cijenu domaće valute izraženu u stranoj valuti bez uzimanja u obzir stopu inflacije, odnosno zanemarujući kupovnu moć. Aprecijacija odnosno deprecijacija ovakve vrste tečaja nam nužno ne mora pokazivati što se događa s konkurentnosti zemlje čiji tečaj aprecira/deprecira.¹⁶

Realni devizni tečaj je nominalni tečaj korigiran za stopu inflacije i on je mnogo važniji, jer inflacija obezvrjeđuje vrijednost novca, smanjuje njegovu kupovnu moć. Korekcijom nominalnog tečaja za stopu inflacije dobiva se realna slika kupovne moći novca i konkurentnosti zemlje. Matematički izraz realnog deviznog tečaja¹⁷:

$$S_r = S \frac{P}{P^*} \quad (1)$$

S_r-indeks realnog deviznog tečaja
S - nominalni devizni tečaj u obliku indeksa
P - indeks domaćih cijena

Za razliku od nominalnog tečaja realni devizni tečaj se ne objavljuje na dnevnim bazama jer se indeksi cijena uobičajeno objavljuju na mjesečnoj bazi.

Efektivni devizni tečaj javlja se kad domaća valuta istovremeno prema određenim valutama aprecira, a prema drugima deprecira. To je vagani prosjek deviznih tečajeva između domaće valute i valute zemalja najvažnijih trgovačkih partnera. Pri tome svaki partner ima svoj ponder.

Druga kategorija podjele deviznog tečaja dijeli ih prema (ne)uplitanju države u određivanje cijene valute, odnosno visine deviznog tečaja. Prema toj podjeli razlikuju se dvije temeljne vrste :


- **fiksni** devizni tečaj (država zakonski povećava/smanjuje vrijednost domaće valute) i
- **fluktuirajući** devizni tečaj (ponuda i potražnja određuju razinu tečaja).

¹⁶Pilbeam, K. (2006): INTERNATIONAL FINANCE, PALGRAVE MACMILLAN, New York, str 10.

¹⁷Pilbeam, K. (2006):Ibid., str. 10

Kako bi se mogla razumjeti razlika između fiksnog i fluktuirajućeg deviznog tečaja prvo će se objasniti dvije temeljne determinante kretanja deviznog tečaja, a to su ponuda i potražnja za određenom valutom.¹⁸

Potražnja za određenom valutom obično je derivirana iz uvoza, transfera u inozemstvo, kredita u inozemstvo itd. te nije potaknuta samom intrinzičnom vrijednosti valute, u ovom slučaju funte, nego onim što funta može kupiti.¹⁹ Na sljedećoj slici prikazana je krivulja potražnje za engleskom funtom te cijena iste izražena u američkim dolarima.



Slika 1: Potražnja za funtom

Izvor: Pilbeam, K. (2006):op.cit., str. 16.

Napomena: skupa funta – mala potražnja za funtom za kupnju britanskih dobara i investiranje u Veliku Britaniju, jeftina funta – velika potražnja za funtom za kupnju britanskih dobara i investiranje u Veliku Britaniju.


Kretanjem s razine deviznog tečaja $1\text{£}=2,00\text{\$}$ na razinu $1\text{£}=1,80\text{\$}$, britanska dobra su za $(1,80-2)/2=-0,1$, odnosno 10% jeftinija.

¹⁸Napomena: Prilikom prikazivanja ponude i potražnje za hipotetski primjer koristit će se valutni par USD/GBP.

¹⁹Pilbeam, K. (2006):op.cit., str. 15

Vidi se da je krivulja potražnje za funtom padajuća, jer će u ovom slučaju američke kompanije biti motivirane uvoziti više robe iz Velike Britanije kako funta deprecira, odnosno trebat će izdvojiti manje dolara za jednu funtu. U slučaju da funta prema dolaru aprecira, američki potrošači će radije kupovati svoju robu nego uvoziti iz Velike Britanije robu koja za njih tada postaje skuplja.

Ponuda deviza funkcija je izvoza, transfera u inozemstvo, inozemnih investicija u zemlji itd.²⁰ Sljedeća slika prikazuje krivulju ponude za funtom.



Slika 2: Ponuda za funtom

Izvor: Pilbeam, K. (2006): op.cit., str. 17

Napomena: skupa funta – za jednu funtu kupuje se više dolara, stoga su američka dobra jeftinija, jeftina funta – jedna funta kupuje manje dolara, stoga su američka dobra skuplja.

Kretanje razine deviznog tečaja $1\text{£}=2,00\$$ na razinu $1\text{£}=1,80\$$ znači da bi za imatelje britanske funte dolar postao skuplji za $(0,56-0,5)/0,5^{21}=0,12$ ili 12% - niža ponuda funte.

²⁰ Lovrinović, I. (2015): op.cit., str. 96.

²¹ Napomena: Ovi brojevi su dobiveni kao recipročna vrijednost tečaja funte, $1/2,00=0,5$, odnosno $1/1,80=0,56$.

Vidi se da je ista promjena tečaja rezultirala 10% jeftinijim dobrima za imatelje eura, a s druge strane su za imatelje dolara europska dobra poskupila za 12% - ovakva razlika koja proizlazi iz istog izračuna, a nije jednaka naziva se Siegelov paradoks.

Gledajući sliku 2 može se primijetiti da je krivulja ponude za određenom valutom, u ovom slučaju funtom rastuća, odnosno postoji pozitivna veza između vrijednosti funte i ponuđene količine na tržištu. Ako vrijednost funte aprecira prema dolaru, odnosno ako funta jača, britanski potrošači radije će kupiti američku robu koja je jeftinija. Slijedom toga dolazi do povećane količine funti na deviznom tržištu kako bi se zamijenile za dolare. S druge strane kada tečaj funte prema dolaru deprecira (npr. s razine 1£=2,00\$ na razinu 1£=1,80\$) britanski potrošači kupuju radije svoju robu nego američku, što rezultira manjom ponudom funti.

Nakon što se detaljno prikazala veza između ponude i potražnje za deviznim tečajem bit će objašnjene dvije glavne kategorije deviznog tečaja: fiksni i fluktuirajući devizni tečaj.


U uvjetima papirnate valute, a na osnovi ponude i potražnje i kretanja cijena, otvara se mogućnost neograničene fluktuacije deviznog tečaja sve dok se te oscilacije ne počnu kontrolirati i sprječavati mjerama državne intervencije. Fiksni devizni tečajevi, ako u takvim uvjetima postoje su lažni i manipulirani jer se održavaju samo mjerama devizne kontrole. Ako nisu poduzete mjere da se ograničavaju i kontroliraju, variraju bez granica i tada postaju fluktuirajući devizni tečajevi.²²

Slobodni, odnosno fluktuirajući ili plivajući devizni tečaj formira se na slobodnom deviznom tržištu pod utjecajem ponude i potražnje te se na nj mjerama ekonomske politike može utjecati. Također, ako država raspolaže s dovoljnom količinom deviznih rezervi može utjecati na samo devizno tržište - kupnjom i prodajom deviza. U slučaju fluktuirajućeg deviznog tečaja nacionalna vlast se prema tečaju odnosi neutralno, dakle, određivanje strukture ili razine deviznog tečaja prepušta automatskim i spontanim odnosima tržišta. No, kako je devizni tečaj jedna od najvažnijih ekonomskih varijabli i ima golemi utjecaj na sve gospodarske odnose potpuna indiferentnost nacionalnih vlasti je privremena, kratkotrajna i praktički nedopustiva. Intervencije nacionalnih vlasti najčešće se provode pomoću deviznih rezervi, deviznih i robnih ograničenja i stabilizacijskih fondova.²³

²²Studentski.hr: Materials, [Internet], raspoloživo na : <http://studentski.hr/system/materials/o/961b690552175852c10c7c133a35935dd34e97c4.zip?1439380096>, [10.07.2018.]

²³Lovrinović, I. (2015): op.cit., str. 88.

Na sljedeće dvije slike (Slika 3 i Slika 4) pokazat će se razlika u fiksnim i fluktuirajućim režimima deviznog tečaja preko krivulja ponude i potražnje.




Slika 3: Fiksni devizni režim

Izvor: Pilbeam, K. (2006):*op.cit.*, str. 20.

Na slici 3 prikazan je ravnotežni fiksni tečaj ($1\text{£}=1,80\text{\$}$) određen od strane nacionalnih vlasti (središnje banke). Ukoliko dođe do porasta potražnje za funtom što rezultira pomakom krivulje potražnje s D_1 na D_2 engleska središnja banka će kako bi izbjegla jačanje funte prodati $Q_1 - Q_2$ funti i kupiti dolare na deviznom tržištu. Prodajom funti porast će njihova ponuda na tržištu sa S_1 na S_2 . Ovakvom intervencijom središnje banke tečaj ostao fiksna na razini $1\text{£}=1,80\text{\$}$. S druge strane, ako dođe do rasta ponude funte na tržištu krivulja ponude se pomiče sa S_1 na S_2 postoji pritisak na devalvaciju funte. Engleska središnja banka će opet intervenirati te kupiti $Q_1 - Q_2$ funti kako bi vratila razinu deviznog tečaja na ravnotežnu ($1\text{£}=1,80\text{\$}$). Ova je intervencija prikazana promjenom krivulje potražnje na slici desno s D_1 na D_2 .

Na slici 4 devizni tečaj je inicijalno određen susretom ponude i potražnje na deviznom tržištu u ravnotežnoj razini ($1\text{£}=1,80\text{\$}$). Ako primjerice dođe do porasta potražnje za uvozom iz UK-a što pomogne krivulju potražnje s D_1 na D_2 , funta će aprecirati prema dolaru (tečaj će narasti sa razine $1\text{£}=1,80\text{\$}$ na $1\text{£}=2,00\text{\$}$). S druge strane, ako na slici 4 s desne strane prikazan je porast ponude funte sa S_1 na S_2 , u ovom slučaju dolazi do deprecijacije funte u odnosu na dolar (tečaj će pasti sa razine $1\text{£}=1,80\text{\$}$ na $1\text{£}=2,00\text{\$}$). Dakle, ukoliko postoji fluktuirajući

režim tečaj se prilagođava zahtjevima ponude i potražnje na deviznom tržištu.²⁴ Predmet ovog rada su fluktuirajući režimi deviznih tečajeva čija se razina na deviznom tržištu mijenja svake sekunde.



Slika 4: Fluktuirajući devizni režim

Izvor: Pilbeam, K. (2006):op.cit., str. 18-20.

2.1.3. Devizno tržište

Već se nekoliko puta upotrijebio pojam deviznog tržišta pa će se u ovom poglavlju i objasniti.

Devizno tržište (engl. foreignexchangemarket) je segment financijskog tržišta na kojem se obavlja kupoprodaja i zamjena deviza te izvedenih financijskih instrumenata nastalih iz osnova deviznih poslova.²⁵ Također, devizno tržište nije fizičko mjesto na kojem se obavlja trgovina devizama. Devizno tržište ujedno predstavlja i najdinamičniji segment ukupnog financijskog tržišta u svijetu na kojem se pribavljaju određene devize potrebne za plaćanje uvoza i izvoza. Sve je veći iznos deviza koje se kupuju zbog kupnje inozemnih vrijednosnica. Devize se kupuju i služe za održavanje likvidnosti pojedine kompanije kao i države.

Sudionici deviznog tržišta su:

- **Središnje banke** različitih zemalja - kontroliraju državne rezerve valuta i intervencijama osiguravaju stabilnost tečaja.

²⁴Pilbeam, K. (2006):op.cit., str. 19.

²⁵Lovrinović, I. (2015): op.cit., str. 199.

- **Komercijalne banke**- također djeluju značajnim iznosima na deviznom tržištu, jer su vlasnice depozita drugih, manjih ponuđača, no također mogu koristiti vlastita sredstva u sudjelovanju na deviznom tržištu
- **Brokerske kuće** su također važan sudionik, one spajaju kupaca i prodavača stranih valuta, također često banke ne trguju direktno jedna s drugom nego preko brokera te za to plaćaju naknadu.²⁶
- **Trgovci pojedinci** - multinacionalne kompanije, inozemni investitori koji trebaju strane valute, odnosno devize radi poslovanja. Najčešće ne kupuju/prodaju valute direktno nego preko komercijalnih banaka.²⁷

2.2 Važnost i značaj deviznog tečaja

Devizni tečaj važna je varijabla sveprisutna u cijeloj ekonomiji, odnosno gospodarstvu. Počnimo od pojedinca koji npr. podiže kredit s valutnom klauzulom. U slučaju deprecijacije domaće valute u odnosu na stranu pojedinac bi morao izdvojiti veću količinu novca za njegovu otplatu. Primjer su stambeni krediti vezani uz švicarski franak, pri čemu su posljedice promjene tečaja preuzeli građani koji su takve kredite uzeli. Nadalje, ako se promatra aktivnost multinacionalnih kompanija koje djeluju u više različitih zemalja, kontinenata, tada je kretanje deviznog tečaja iznimno bitno jer će utjecati na odluku kompanija o financiranju, investiranju, hedgingu²⁸ te odluci hoće li poduzeće reinvestirati ili remitirati sredstva tvrtke „kćeri“. Dakle, kod multinacionalnih kompanija jedan od bitnih rizika promjene svjetskih cijena je i promjena razine deviznog tečaja.

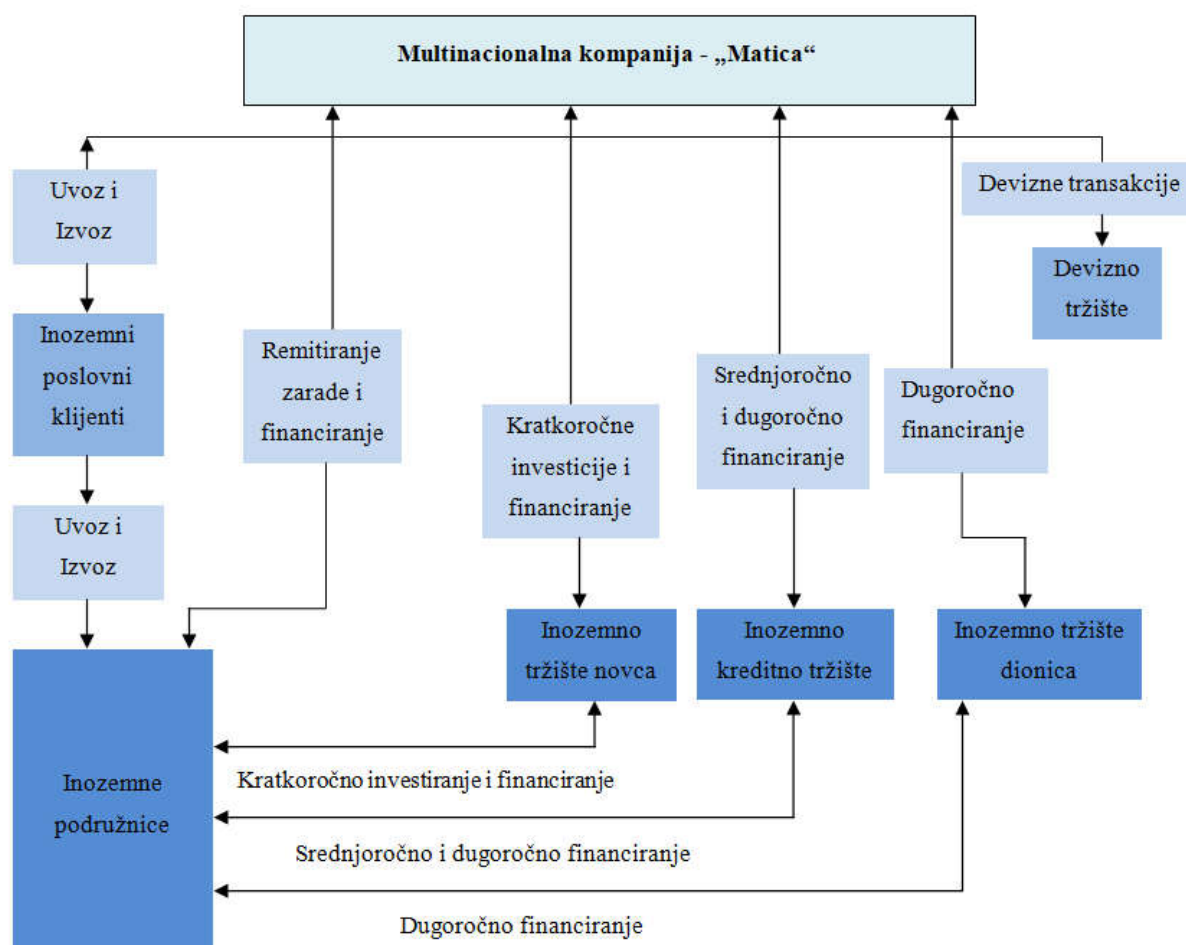
Slika 5 prikazuje novčane tokove multinacionalne kompanije. Ovi novčani tokovi mogu biti klasificirani u četiri korporativne funkcije. Prva funkcija je inozemna trgovina s poslovnim partnerima. Izvoz generira inozemne priljeve, dok uvoz generira inozemne odljeve novca iz kompanije. Sljedeća funkcija su direktna inozemna ulaganja (engl. FDI - directforeigninvestment), ili akvizicije. Ova funkcija u početku generira inozemne odljeve novca, a nakon nekog vremena i priljeve putem remitiranih sredstava tvrtke „kćeri“ ili zbog prodaje inozemnih sredstava. Treća funkcija podrazumijeva kratkoročne investicije u inozemstvo ili financiranje inozemnim vrijednosnicama. Posljednja, ali ne i manje bitna

²⁶ Naknada brokerskoj kući ne zaračunava se kao postotak na transakciju nego kao – spread, odnosno razlika između cijene kupnje i prodaje.

²⁷EuroFX: Sudionici na deviznom tržištu, [Internet], raspoloživo na :<http://www.eurofx.ru/hr/uchastniki-valyutnogo-rynka-foreks/>, [11.07.2018.]

²⁸Poslovno-financijska strategija izbjegavanja ili umanjenja nastupa rizika, tj. gubitka, kod jedne operacije, poduzimanjem druge operacije.

funkcija obuhvaća dugoročna inozemna financiranja na inozemnom tržištu kapitala putem obveznica ili dionica.²⁹



Slika 5: Inozemni novčani tokovi multinacionalne kompanije

Izvor: Izrada autorice prema Madura, J. (2008): International Financial Management, Thomson Higher Education, 9th edition, str. 71.

Osim utjecaja na pojedince i kompanije, važan je i utjecaj deviznog tečaja na varijable ekonomske politike. Promjena deviznog tečaja utječe na cijene, rentabilnost izvoza, ali i na domaće cijene izvoznih dobara. Na taj način promjena deviznog tečaja utječe na promjenu relativnih cijena, ali i na redistribuciju dohotka, relokaciju ekonomskih resursa i na tempo gospodarskog razvoja. Razina deviznog tečaja i njegova (ne)stabilnost danas se uzima kao pokazatelj gospodarske snage, stabilnosti i stanja gospodarstva. Možemo reći da je devizni


²⁹Madura, J. (2008): op.cit., str. 70-71.

tečaj poveznica između raznih nacionalnih monetarnih sustava, pri čemu se svaka njegova promjena odražava na međusobne, ali i ukupne svjetske odnose.³⁰

Postoje brojna istraživanja koja nastoje razviti modele koji bi donekle mogli predvidjeti kretanje deviznog tečaja. U ovom radu će se također nastojati donijeti zaključci o najvažnijim determinantama utjecaja na devizni tečaj. Slijedom toga će se u sljedećem poglavlju teoretski opisati varijable utjecaja na devizni tečaj.

2.3. Čimbenici formiranja deviznog tečaja

Kao prvi spomenuti čimbenici utjecaja na devizni tečaj su ponuda i potražnja za određenom valutom prikazane na slikama 1 i 2. Iz navedenih slika se može primijetiti da je krivulja potražnje za određenom valutom - u ovom slučaju funtom pozitivna, dok je funkcija potražnje negativno nagnuta. Na sljedećoj slici prikazano je određivanje ravnotežnog deviznog tečaja istovremenim djelovanjem krivulja ponude i potražnje.



Slika 6: Određivanje ravnotežnog deviznog tečaja

Izvor: Pilbeam, K. (2006):op.cit., str. 18.

³⁰Lovrinović, I. (2015): op.cit., str. 83-85.

Promjena ravnotežnog deviznog tečaja uvelike ovisi o samoj likvidnosti određene devize, koja je ujedno uvjetovana i potražnjom za tom devizom. Ukoliko je spot devizno tržište za određenom devizom - u ovom slučaju funtom stalno i likvidno, njezin tečaj neće znatno oscilirati oko onog ravnotežnog (1£=1,80\$). Velikih oscilacija neće biti jer tečaj likvidne valute nije osjetljiv na pojedinačne prodaje ili kupnje. S druge strane, ukoliko je funta nelikvidna valuta njezin tečaj bi bio visoko osjetljiv i nestabilna na pojedinačne transakcije. Razlog tim velikim oscilacijama je nedovoljan broj „igrača“, odnosno kupaca i prodavača određene devize na tržištu koji bi mogli „odigrati“ suprotnu transakciju i tečaj vratiti u ravnotežu. Ravnotežni tečaj će se mijenjati iz sekunde u sekundu kao se mijenjaju ponuda i potražnja.

Postoji velik broj varijabli koji utječu na ponudu i potražnju za određenom devizom.

Sljedeća jednačica sumira čimbenike koji mogu utjecati na kretanje deviznog tečaja:³¹

$$e = f(\Delta INF, \Delta INT, \Delta INC, \Delta GC, \Delta EXP) \quad (2)$$

e - postotna promjena spot deviznog tečaja


ΔINF - promjena razlike između domaće i inozemne inflacije

ΔINT - promjena razlike između domaće i inozemne kamatne stope

ΔINC - promjena razlike između domaće i inozemne razine dohotka

ΔGC - promjena deviznih kontrola i

ΔEXP - promjena u očekivanjima budućih deviznih tečajeva



Slika 7: Utjecaj porasta inflacije u SAD-u na ravnotežni tečaj britanske funte


Izvor: Madura, J. (2008): op.cit., str. 90.

³¹Madura, J. (2008): op.cit., str. 89.

Slika 7 prikazuje pomak krivulja ponude i potražnje za britanskom funtom uslijed porasta inflacije u SAD-u.

Kroz međunarodnu razmjenu na ponudu i potražnju za tečajem i na samo kretanje tečaja utječe i razlika u stopama inflacije između promatranih zemalja. Primjerice, ako stopa inflacije znatno poraste u SAD-u, dok u Velikoj Britaniji ostane ne promijenjena ili na manjoj razini, tada američka roba postaje skuplja za inozemne kupce. Istovremeno raste potražnja za britanskim proizvodima u SAD-u, te samim time raste i potražnja za funtom - radi financiranja uvoza britanskih proizvoda, što u konačnici ima pozitivan utjecaj na vrijednost funte izraženu preko dolara. Također, dolazi do smanjenja ponude funte prema dolaru. Dakle, ako kao domaću valutu promatramo američki dolar, tada porastom stope inflacije u tuzemstvu (SAD-u) dolazi do deprecijacije domaće valutu - dolara, dok istovremeno funta jača, odnosno aprecira. U konačnici će se pod pritiskom povećane potražnje i smanjene ponude postaviti novi ravnotežni tečaj na višoj razini (tečaj raste s $1\text{£}=1,55\text{\$}$ na $1\text{£}=1,57\text{\$}$). U slučaju da je inflacija u Velikoj Britaniji rasla više, dogodila bi se suprotna situacija - deprecijacija funte i aprecijacija dolara.³²

Sljedeći čimbenik koji djeluje na ponudu i potražnju za određenom devizom - u ovom slučaju funtom je promjena u relativnim kamatnim stopama koje utječu na kretanje investicija u svijetu.



Slika 8: Utjecaj porasta kamatnjaka u SAD-u na ravnotežni tečaj britanske funte

Izvor: Madura, J. (2008): op.cit., str. 90.

³²Napomena: Pod pretpostavkom da američke i britanske kompanije prodaju dobra koja su međusobni supstituti.

Ako kamatnjak u SAD-u poraste, a u Velikoj Britaniji ostane isti, američki će investitori smanjiti potražnju za funtom jer im je isplativije novac uložiti u vlastitoj zemlji. Rast kamatne stope u SAD-u motivira britanske investitore da višak novca ulože u SAD-e što će dovesti do povećanja ponude britanske funte i povećanja potražnje za američkim dolarom. Navedeno dovodi do formiranja novog ravnotežnog tečaja na nižoj razini (tečaj pada s 1£=1,57\$ na 1£=1,55\$) zbog istovremenog povećanja ponude i smanjenja potražnje za britanskom funtom. To znači da će britanska funta deprecirati. Ukoliko dođe do suprotne pojave, da kamatna stopa u Velikoj Britaniji poraste, a u SAD-u ostane ista vrijedi obrnuta logika.

Tečaj domaće valute ponekad ne određuju samo kretanja između dvije zemlje čije valute uspoređujemo, već značajan utjecaj mogu imati događanja u trećoj zemlji.³³ Primjerice, ako kamatna stopa u Eurozoni poraste više nego li u SAD-u i Velikoj Britaniji, to može biti privlačno za američke i britanske investitore pa počnu ulagati u Eurozonu. Navedeno povećava potražnju za eurima s jedne strane te s druge strane povećava ponudu dolara i funti. Dakle, funta može deprecirati i zbog utjecaja kamatnjaka u Eurozoni.

Iako visoki kamatnjaci mogu privući novac inozemnih investitora, oni također mogu biti signal očekivanog rasta inflacije i deprecijacije te valute u budućnosti. Tada će investitori uložiti svoj novac u stranu zemlju onda kada je realna kamatna stopa u inozemstvu veća nego u njihovoj ili nekoj drugoj zemlji.

Navedeno je poznato kao Fisherov efekt³⁴:

Realna kamatna stopa \approx Nominalna kamatna stopa - Stopa inflacije (3)


Treći faktor koji preko uvoza djeluje na potražnju za određenom valutom je promjena u razini dohotka, odnosno bruto domaćeg proizvoda (BDP-a).

Ako dođe do porasta razine dohotka u SAD-u, dok u drugoj promatranoj državi - Velikoj Britaniji razina dohotka ostane nepromijenjena, potražnja za inozemnim dobrima, odnosno uvoz inozemnih (britanskih) dobara u SAD-e će porasti. Time dolazi i do porasta potražnje za britanskom funtom (dok se pretpostavlja da će ponuda ostati nepromijenjena) radi financiranja uvoza britanskih dobara. Dolazi do aprecijacije funte u odnosu na dolar, te se tečaj formira na većoj ravnotežnoj razini.

³³Madura, J. (2008): op.cit., str. 91.

³⁴Madura, J. (2008): Ibid., str. 91.

Potrebno je napomenuti da ova varijabla može imati i pozitivan utjecaj na tečaj domaće valute u ovom primjeru funte. Naime, promjena razine dohotka može preko kamatne stope indirektno djelovati na tečaj. Porast razine dohotka, odnosno rasta gospodarstva može biti naznaka rasta kamatnih stopa u budućnosti, što može rezultirati rastom vrijednosti domaće valute (aprecijacija funte). Također, ako dođe do pada razine dohotka u SAD-u onda se tečaj kreće u suprotnom smjeru u oba slučaja.



Slika 9: Utjecaj porasta kamatnjaka u SAD-u na ravnotežni tečaj britanske funte

Izvor: Madura, J. (2008): op.cit., str. 92.

Sljedeći, četvrti čimbenik odnosi se na promjenu deviznih kontrola. Vlade pojedinih država mogu svojim mjerama uvelike utjecati na ravnotežni devizni tečaj, te najčešće tečaj odmah reagira na te mjere, čak i na same najave mjera.

Neke od mjera s kojim vlada može utjecati na devizni tečaj su: uvođenje određenih zabrana na deviznom tržištu, uvođenje trgovačkih barijera te intervencija prodajom/kupnjom određenih valuta.³⁵

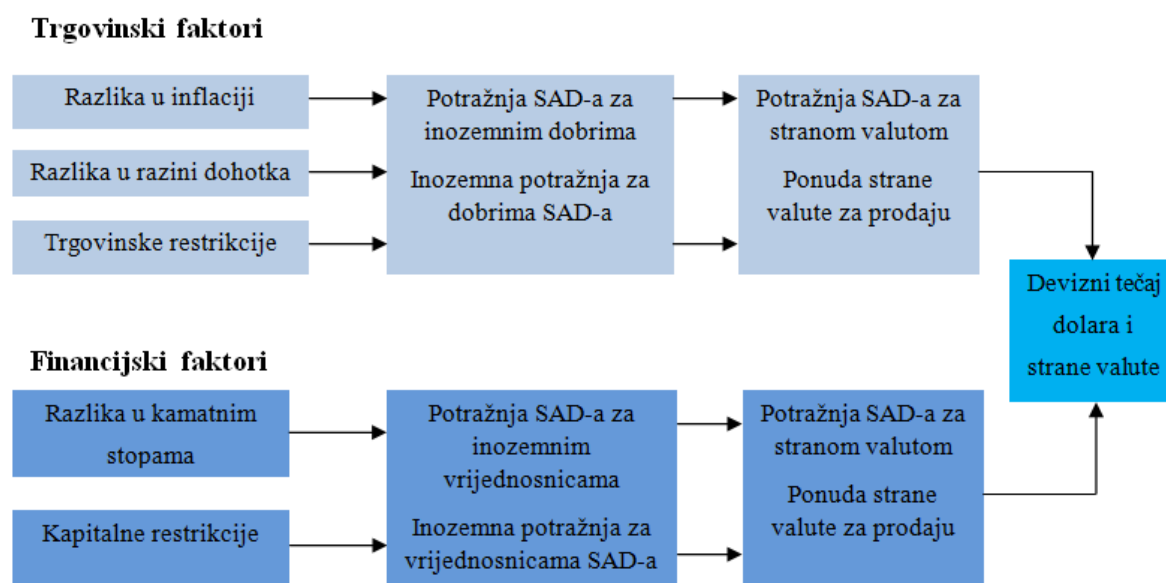
Posljednji čimbenik odnosi se na očekivanja koja su ujedno i psihološki čimbenik koji je stvar percepcije pojedinca. Kao i svako drugo financijsko tržište, devizno tržište iznimno je osjetljivo te brzo i nepredvidljivo reagira na svaku novu vijest bilo pozitivnu ili negativnu. Osim očekivanja postoji još jedan nepredvidljivi faktor, a to su špekulacije. Špekulanti svakodnevno prate različite čimbenike utjecaja na devizni tečaj te očekivanja o budućim makroekonomskim pokazateljima određenih država i na temelju navedenog donose svoje

³⁵Lovrinović, I. (2015): op.cit., str. 100.

odluke o kupnji/prodaji deviza. Upravo zbog nekada prejake reakcije špekulanata na vijesti događa se da pojedina valuta u jednom satu raste, dok već u drugom njezin tečaj pada. Vijesti na koje špekulanti reaguju mogu biti prognoze makroekonomskih varijabli određene države. Također to mogu biti i izjave visokih dužnosnika ili predsjednika „velikih“ ekonomskih sila u svijetu.

Posljednja dva čimbenika iz jednadžbe (2): promjena deviznih kontrola i promjena u očekivanjima budućih deviznih tečajeva će biti isključeni iz empirijskog djela istraživanja zbog nedostatka podataka i nemogućnosti kvantificiranja.

Prethodno su opisana pojedina djelovanja različitih čimbenika koji utječu na formiranje deviznog tečaja, no u stvarnosti postoji interaktivno djelovanje navedenih čimbenika. Prilikom djelovanja više čimbenika na devizni tečaj među dvjema promatranim valutama, treba se promatrati i interakciju tih čimbenika zajedno, tako da će individualni utjecaji nekih čimbenika utjecati više nego drugi. Koja će varijabla na kraju imati prevladavajući utjecaj na promjenu deviznog tečaja ovisi o tome jesu li među dvjema državama više zastupljeni trgovinski ili financijski odnosi. Sljedeća slika sumira djelovanje čimbenika na devizni tečaj prema zastupljenosti međunarodnih trgovinskih odnosa i prema međunarodnim financijskim tokovima.



Slika 10: Utjecaj čimbenika na devizni tečaj prema trgovinskim/financijskim odnosima

Izvor: Izrada autorice prema Madura, J. (2008): op.cit., str. 92.

Ukoliko su između dvije zemlje razvijeniji trgovinski odnosi, to znači da će na devizni tečaj najviše utjecati promjene u inflacijama, dohotku i trgovinskim ograničenjima. Tada su

navedena tri čimbenika bitna u formiranju tečaja te dalje utječu na potražnju i ponudu za određenom stranom valutom. S druge strane ako promatrane zemlje imaju razvijenije kapitalne tokove na formiranje deviznog tečaja značajnije utječu promjene u kamatnjacima i ograničenju kretanja kapitala.

Primjerice, ako pretpostavimo istodobni rast kamatnjaka i inflacije u SAD-u, a ako do promjena nije došlo u npr. Velikoj Britaniji, porast kamatnjaka dovodi do deprecijacije odnosno slabljenja funte dok istovremeno porast inflacije dovodi do aprecijacije - jačanja funte. Kakav će u konačnici biti rezultat (aprecijacija ili deprecijacija) na tečaj funte ovisi o tome prevladavaju li trgovinske ili kapitalne transakcije među ovim dvjema zemljama. Ukoliko je volumen trgovanja veći prevladavajući utjecaj ima inflacija, a ako su veći kapitalni tokovi tada prevladavajući utjecaj ima promjena kamatnjaka.

Osim navedenih teorijskih čimbenika utjecaja na devizni tečaj u ovom radu će se pokušati dokazati utjecaj i sljedeća tri čimbenika; cijene nafte preko WTI indeksa, VIX indeksa rizičnosti i CCI indeksa. Očekivani utjecaji navedenih varijabli detaljno su objašnjeni u poglavlju 1.2. Ciljevi i hipoteze istraživanja prilikom formiranja hipoteza ovog rada.

2.4. Teorije deviznih tečajeva

Postoje mnogobrojne teorije deviznih tečajeva, no za potrebe ovog rada u nastavku bit će objašnjene dvije, PPP teorija i MFE teorija.

2.4.1. Teorija pariteta kupovnih moći - PPP teorija

Teorija pariteta kupovnih moći jedna je od ključnih teorija koja nastoji objasniti i kvantificirati odnos između inflacije i deviznog tečaja. Prema PPP teoriji, određeni standardizirani proizvod bi u dvije različite zemlje trebao imati jednaku cijenu.³⁶ Navedeno bi značilo da je devizni tečaj određen na ispravan način jer se isti proizvod u različitim zemljama može kupiti po istoj cijeni. Primjerice, ako boca nekog određenog soka naranče od 0,5l u SAD-u stoji 2\$, tada bi isti sok i u Velikoj Britaniji trebao stajati 1,52£. Zbog toga se ova teorija u literaturi naziva i „Zakon jedne cijene“(engl. Thelawof one price). Ukoliko nije tako, prema PPP teoriji devizni tečaj jedne od valuta se mora promijeniti. Može se reći da u dugom roku ova teorija vrijedi, ali u kratkom roku je podložna devijacijama i nestabilnosti.³⁷

³⁶Gandolfo, G. (2002.): International Finance and Open-Economy Macro-economics, Science and Business Media, Springer

³⁷Lovrinović, I. (2015): op.cit., str. 123.

Kad bi PPP teorija bila jedina determinanta utjecaja na nominalni devizni tečaj između dvije valute, realni devizni tečaj bi tijekom vremena bi konstantan.³⁸

PPP teorija pojavljuje se u dva oblika:

- **apsolutna i**
- **relativna.**

Apsolutna PPP teorija zasniva se na činjenici da u međunarodnoj razmjeni ne postoje ikakve trgovinske barijere ni transportni troškovi i da potrošači kupuju dobra tamo gdje su najjeftinija. Ukoliko su navedene pretpostavke zadovoljene moguće je uspoređivati cijene među dvjema zemljama. Pretpostavimo da postoje dvije košare istih proizvoda od kojih je jedna proizvedena u SAD-u, dok je druga proizvedena u Velikoj Britaniji. Ako je cijena američke košarice jeftinija tada će ih biti jeftinije uvoziti u Veliku Britaniju. Prema PPP teoriji ova bi se činjenica trebala reflektirati na devizni tečaj funte prema euru, kako bi se cijene košarica istih standardiziranih proizvoda uskladile.³⁹

U stvarnosti troškovi prijevoza kao i različite trgovinske barijere postoje. Stoga apsolutna PPP teorija ne vrijedi i jaz među cijenama nastavlja se pojavljivati. Primjerice, ukoliko bi troškovi prijevoza robe iz SAD-a bili veći tada bi se cijene američkih proizvoda izjednačile ili bile više od onih u Velikoj Britaniji te američka roba više nebi bila konkurentna.

Relativna PPP teorija uzima u obzir tržišne nesavršenosti kao što su postojanje troškova prijevoza, postojanje trgovinskih barijera, kvota ili tarifa i računa se u odnosu prema određenom baznom razdoblju. Prema ovoj varijanti cijene jednakih proizvoda u dvije zemlje neće biti iste mjerene u jednoj valuti sve dok se trgovinske barijere i transportni troškovi ne promijene.⁴⁰

Pretpostavimo da je indeks cijena prije inflacije u zemlji i inozemstvu 100 (bazno razdoblje). Nadalje, pretpostavimo da je došlo do porasta cijena u zemlji (h) i inozemstvu (f) u sljedećem razdoblju, s tim da I_h označava stopu inflacije u tuzemstvu dok I_f označava stopu inflacije u inozemstvu. Zbog inflacije cijenovni indeks u zemlji sada je jednak:⁴¹

$$P_h (1 + I_h), \quad (3)$$

odnosno u inozemstvu

³⁸ J., Schnatz B., (2000): The determinants of euro-dollar exchange rate - Synthetic fundamentals and non-existing currency, Deutsche Bundesbank, Frankfurt am Main, str. 1

³⁹ Madura, J. (2008): op.cit., str. 214.

⁴⁰ Lovrinović, I. (2015): op.cit., str. 124.

⁴¹ Madura, J. (2008): op.cit., str. 216.

$$P_f (1 + I_f), \quad (4)$$

Ukoliko je stopa inflacije u inozemstvu veća od one u zemlji, $I_f > I_h$, a devizni tečaj između dvije valute ostane nepromijenjen, kupovna moć potrošača bit će veća pri kupnji domaćih u odnosu na inozemna dobra te u tom slučaju PPP teorija ne postoji. Ako je stopa inflacije u zemlji veća od one u inozemstvu $I_h > I_f$, kupovna moć veća je pri kupnji inozemnih dobara te PPP također ne vrijedi.

Teorija pariteta kupovnih moći pretpostavlja da će se devizni tečaj prilagoditi kao posljedica promijene razlike u inflacijama među dvije promatrane zemlje. Dakle, pri PPP teoriji vrijedi da će promjene inflacije biti „offset“ s promjenom u deviznom tečaju kako bi se održao paritet kupovne moći.

Odnos između relativne promjene razine cijena i relativne promjene deviznog tečaja prema PPP teoriji:⁴²

$$e_f = \frac{1+I_h}{1+I_f} - 1 \quad (5)$$

e_f - postotna promjena vrijednosti strane valute

Ukoliko je $I_h > I_f$, e_f bi trebala biti pozitivna, što znači da bi strana valuta trebala aprecirati. S druge strane, ako je $I_f > I_h$ tada je e_f negativna i strana valuta deprecira u odnosu na domaću.

Postoji i treći „oblik“ PPP teorije - pojednostavljena PPP teorija:⁴³

$$e_f \approx I_h - I_f \quad (6)$$

Ovom jednadžbom se približno može aproksimirati promjena deviznog tečaja razlikom u stopama inflacije u zemlji i inozemstvu.

2.4.2. Međunarodni Fisherov efekt - IFE

Međunarodnim Fisherovim efektom objašnjena je veza između kretanja kamatnih stopa i deviznog tečaja određene valute. Prije pojašnjenja utjecaja kretanja kamatnih stopa na devizni tečaj, potrebno je objasniti vezu između kamatnih stopa i inflacije.

Svaki investitor želi da njegov prinos na investiciju u različitim zemljama donosi jednak prinos ako su razine rizika jednake. U tom slučaju kao uzrok razlike u kamatnjacima između različitih zemalja pojavljuju se različita očekivanja u stopama inflacije.⁴⁴

⁴² Vidi: Madura, J. (2008): op.cit., str. 216. za derivaciju formule odnosa između relativne promjene razine cijena i relativne promjene deviznog tečaja prema PPP teoriji.

⁴³ Madura, J. (2008): op.cit., str. 217.

⁴⁴ Napomena: Vidi Fisherovu formulu (3)

Međunarodni Fisherov efekt (MFE) sugerira da će valuta na koju se odnose više kamatne stope deprecirati, kao i neke valuta u kojoj je zabilježena visoka stopa inflacije. Također, Fisher se nužno ne koristi razlikama u kamatnjacima da objasni promjenu deviznog tečaja. Ako je kamatna stopa viša u zemlji „X“ nego u zemlji „Y“ i unatoč tome nema priljeva kapitala u zemlju „X“, onda je to zbog toga što tržište očekuje da će u budućnosti valuta zemlje „X“ deprecirati ili devalvirati u odnosu na valutu zemlje „Y“. Dakle, MFE teorija se ne slaže s mišljenjem da bi viši kamatnjak u jednoj zemlji trebao biti magnet za investitore iz drugih zemalja.⁴⁵ Tamo gdje se očekuje viši kamatnjak nema razloga vjerovati da će biti pritiska na tečaj, jer je viši kamatnjak kompenzirao očekivanu deprecijaciju valute kako sugerira PPP teorija.⁴⁶

Dakle, MFE teorija sugerira da bi devizni tečaj između valuta dviju država trebao biti određen s razlikom u nominalnim kamatnim stopama između tih zemalja. Pritom bi valuta države s nižim nominalnim kamatnim stopama trebala aprecirati u odnosu na onu s višim kamatnim stopama. Nominalna kamatna stopa jednaka je realnoj kamatnoj stopi uvećanoj za inflaciju.

Ukoliko su u nekoj zemlji kamatne stope visoke u dužem vremenskom periodu, ona je očito suočena s problemom inflacije. Iznimno visoke stope inflacije ljude tjeraju da se riješe novca i pretvaraju ga u robu. Unatoč visokim kamatnjacima tada se ne stimulira štednja nego raste sklonost iznajmljivanju novca, jer znaju da će poslije trebati platiti više novca za isti proizvod. U ovakvoj situaciji ni visoke kamatne stope neće potaknuti investitore da ulože svoj novac u ovu zemlju, jer imaju visoka inflatorna očekivanja koja će utjecati da valuta zemlje s visokim kamatnim stopama slabi. S druge strane ako dođe do porasta kamatnjaka u zemlji koja duže vrijeme ima stabilne kamatne stope investitori neće očekivati kompenzacijski efekt u vidu pada vrijednosti valute.⁴⁷

U tablici 1 prikazan je primjer utjecaja Fisherova efekta iz perspektive investitora iz različitih zemalja.

⁴⁵ Napomena: osim tržišnih očekivanja deprecijacije valute s višom kamatnom stopom, na to što nema priljeva kapitala u zemlju s višom kamatnom stopom mogu utjecati razne makroekonomske varijable i poslovna klima određene zemlje (npr. porezni sustav, zabrana reemitiranja sredstava u domicilnu državu, itd.).

⁴⁶Madura, J. (2008): op.cit., str. 217.

⁴⁷Lovrinović, I. (2015): op.cit., str. 132.

Tablica 1: Prikaz međunarodnog Fisherovog efekta iz perspektive različitih

Investitor rezident u	Domaća kamatna stopa	=očekivana inflacija	+ realni povrat	Investira u	Kamatna stopa zarađena u inozemstvu	+ očekivana promjena vrijednosti strane valute	= neto povrat od ulaganja u inozemstvo
SAD	5%	2%	3%	Euro	6%	-1%	5%
				Japan	7%	-2%	5%
				Velika Britanija	9%	-4%	5%
Eurozona	6%	3%	3%	SAD	5%	1%	6%
				Japan	7%	-1%	6%
				Velika Britanija	9%	-3%	6%
Japan	7%	4%	3%	SAD	5%	2%	7%
				Euro	6%	1%	7%
				Velika Britanija	9%	-2%	7%
Velika Britanija	9%	6%	3%	SAD	5%	4%	9%
				Euro	6%	3%	9%
				Japan	7%	2%	9%

Izvor: Izrada autorice

U tablici 1 dani su podaci o domaćim kamatnim stopama, očekivanoj inflaciji i realnom povratu. Očekivana promjena u vrijednosti strane valute izračunata je preko PPP teorije kao $e_f \approx I_h - I_f$. Da se primjetiti da je neto povrat od ulaganja u inozemstvo jednak kao i domaća kamatna stopa.

Dakle, ako je npr. nominalni kamatnjak u SAD-u 5%, a očekivana stopa inflacije 2%, realni povrat investicije iznosi 3%. Nominalni kamatnjak u npr. Japanu iznosi 7% i ako investitori očekuju isti prinos kao i u SAD-u (3%), tada stopa inflacije iznosi 4%. Prema PPP teoriji japanski jen bi trebao deprecirati za 2% (2%-4%=-2%). Zbog toga američki investitori neće profitirati investiranjem u Japan. Ostvarit će nominalni prinos od 7%, ali će pri konverziji japanskog jena u američki dolar izgubiti 2% zbog deprecijacije jena, tako da će u konačnici ostvariti prinos od 5%, a isti bi ostvarili investirajući u vlastitu zemlju.

Odnos između relativne promjene kamatnih stopa i relativne promjene deviznog tečaja prema MFE teoriji:⁴⁸

$$e_f = \frac{1+i_h}{1+i_f} - 1 \quad (7) \quad e_f - \text{postotna promjena vrijednosti strane valute}$$

⁴⁸ Vidi: Madura, J. (2008): op.cit., str. 216. za derivaciju formule odnosa između relativne promjene razine cijena i relativne promjene deviznog tečaja prema PPP teoriji.

Ukoliko je $i_h > i_f$, e_f bi trebala biti pozitivna, što znači da bi strana valuta trebala aprecirati, odnosno strana valuta će aprecirati kad je inozemni kamatnjak niži od onog u tuzemstvu. S druge strane, ako je $i_f > i_h$ tada je e_f negativna i strana valuta deprecira u odnosu na domaću.

Pojednostavljena varijanta MFE :

$$e_f \approx i_h - i_f \quad (8)$$

i_h - kamatna stopa u zemlji
 i_f - kamatna stopa u inozemstvu

Može se uočiti sličnost formula aproksimacije promjene deviznog tečaja između MFE i PPP teorije, razlika je samo u determinirajućoj varijabli - kamatna stopa odnosno inflacija.

MFE teorija još se naziva i uvjet nepokrivenog kamatnog pariteta (engl. uncovered interest rate parity). Unutar teorije kamatnog pariteta postoji i pokriveni kamatni paritet, no navedeno neće biti predmet daljnjeg istraživanja.

Primjenjujući navedene teorije može se donijeti generalni zaključak, zemlje s visokom inflacijom imaju veće kamatne stope (zbog MFE teorije). Njihove valute imaju trend deprecijacije (zbog PPP i MFE teorije).

2.5. Tehnike predviđanja deviznog tečaja

Već ranije, na početku rada istaknuta je važnost deviznog tečaja za pojedinca, kompaniju koja posluje u inozemstvu i za cjelokupno gospodarstvo. Upravo zbog važne ekonomske uloge deviznog tečaja, u ovom poglavlju će se objasniti četiri različite tehnike predviđanja deviznog tečaja:

- tehnička analiza
- fundamentalna analiza
- tržišno utemeljeno predviđanje i
- miks tehnika

Tehnička analiza predviđanja deviznog tečaja nastoji korištenjem povijesnih podataka predvidjeti buduće kretanje tečaja. Ova metoda nema nikakvo teorijsko uporište te je usmjerena na kratkoročno predviđanje deviznog tečaja, dok je u dugom roku izrazito nepouzdana. Tehničkom analizom mogu se uočiti uzorci kretanja pojedinog tečaja, no oni zbog volatilnosti i iznimne reakcije deviznog tečaja na vijesti već sutra mogu izgledati potpuno drugačije.

Također, ukoliko određeni tehnički model predviđanja deviznog tečaja ostvaruje profit, u vremenu dok ga i ostali počnu koristiti više neće biti koristan u svrhu ostvarivanja špekulativnih profita. Unatoč svemu tome tehnička analiza je prilično raširena, te neki zastupaju tezu da sve što trebaju znati o određenoj valuti je već sadržano u njezinoj cijeni, jer se tržište konstantno mijenja i prilagođava vijestima.⁴⁹ Naravno, ovo ne može biti razlog da neka velika multinacionalna kompanija za svoje potrebe npr. hedgiranja koristi samo tehničku analizu u predviđanju kretanja deviznog tečaja koji joj je iznimno bitan za poslovanje.

Fundamentalna analiza temelji se na povezivanju makroekonomskih varijabli i deviznog tečaja. Promjena spot deviznog tečaja funkcija je nekoliko varijabli koje su već prethodno spomenute i opisane u poglavlju - 2.3. Čimbenici formiranja deviznog tečaja⁵⁰:

- ΔINF - promjena razlike između domaće i inozemne inflacije
- ΔINT - promjena razlike između domaće i inozemne kamatne stope
- ΔINC - promjena razlike između domaće i inozemne razine dohotka
- ΔGC - promjena deviznih kontrola i
- ΔEXP - promjena u očekivanjima budućih deviznih tečajeva

Na temelju uvrštavanja varijabli u regresijsku analizu trebali bi dobiti rezultate utjecaja pojedine varijable na devizni tečaj i približno točne podatke o kretanju tečaja.

Primjerice, regresijska jednadžba u kojoj promatramo tečaj američkog dolara i britanske funte može izgledati ovako:

$$e_{\$,t} = b_0 + b_1 INF_{t-1} + b_2 INC_{t-1} + b_3 INT_t + \mu_t \quad (9)$$

pri čemu je

$e_{\$,t}$ - postotna promjena vrijednosti dolara kroz vrijeme t ,

b_0 - konstanta,

b_1 - osjetljivost (elastičnost) $e_{\$,t}$ na promjene INF_{t-1} ,

INF_{t-1} - britanska inflacija umanjena za američku inflaciju u razdoblju $t-1$,

b_2 - osjetljivost (elastičnost) $e_{\$,t}$ na promjene INC_{t-1} ,

INC_{t-1} - britanska stopa rasta umanjena za američku stopu rasta za razdoblje $t-1$,

b_3 - osjetljivost (elastičnost) $e_{\$,t}$ na promjene INT_t ,

INT_t - kamata stopa na funtu umanjena za kamatnu stopu na dolar za razdoblje t i

⁴⁹Lovrinović, I. (2015): op.cit., str. 244.

⁵⁰Madura, J. (2008): op.cit., str. 254.

μ_t - rezidualno odstupanje

Utjecaj svake od navedenih varijabli opisan je u poglavlju 2.3., treba napomenuti da određene varijable utjecaja na devizni tečaj kao što su u ovom primjeru inflacija i dohodak mogu imati tzv. „odgođeni“ učinak na kretanje deviznog tečaja. To znači da promjena inflacije ili dohotka danas utječe na buduće kretanje deviznog tečaja.

Tržišno utemeljeno predviđanje obuhvaća predviđanje deviznog tečaja primjenom tržišnih indikatora te se može temeljiti na spot ili terminskom⁵¹ deviznom tečaju. Ukoliko se odabere spot tečaj, očekuje se kako se on neće mijenjati. Ako se procjenjuje da će npr. dolar aprecirati prema euru u sljedećem razdoblju, onda će špekulanti kupovati dolare, a prodavati eure čime će dodatno utjecati na aprecijaciju dolara. Ako se u analizi koristi terminski tečaj, tada se smatra da je on prediktor budućeg spot tečaja određene valute. Ako špekulanti očekuju da će spot tečaj, primjerice dolara biti viši od sadašnjeg oni će na terminskom tržištu kupovati dolare koje će istekom ugovora prodati i ostvariti premiju.⁵²

Miks tehnika predviđanja deviznog tečaja

Zbog toga što se nijedna tehnika predviđanja nije pokazala superiornom nad ostalima, neke kompanije u predviđanju kretanja deviznog tečaja koriste kombinaciju više tehnika. Svakoj se tehnici dodjeljuje određeni ponder u cjelokupnom predviđanju deviznog tečaja i to na način da je zbroj svih pondera 100%. Tehnike koje su procijenjene kao pouzdanije imaju veći ponder i obrnuto. Ponekad, ista tehnika ima različiti ponder u predviđanju tečajeva različitih valuta. Primjerice, u predviđanju kretanja deviznog tečaja jena veći ponder može imati tržišno utemeljeno predviđanje, dok kod tečaja dolara veći ponder može imati fundamentalna analiza. Također, ista tehnika može imati i različiti ponder u predviđanju tečaja iste valute, ali za različita razdoblja.⁵³

⁵¹ U terminskom ugovoru riječ je o kupnji ili prodaji valute na određeni datum u budućnosti prema danas dogovorenom tečaju.

⁵² Lovrinović, I. (2015): op.cit., str. 254.

⁵³ Madura, J. (2008): op.cit., str. 261.

3. KARAKTERISTIKE DRŽAVA ODABRANIH VALUTA

Svako gospodarstvo ima određene karakteristike koje je potrebno poznavati kako bi se shvatio utjecaj određenih makroekonomskih varijabli na kretanje tečaja određene valute. Pojedina varijabla intenzitet njezine promjene neće isto utjecati na različita gospodarstva i kretanje tečaja različitih valuta. Razumijevanje same strukture pojedinog gospodarstva i značenja najvažnijih makroekonomskih varijabli ključno je za analizu spot deviznog tržišta. Potrebno je imati i uvid u međudnose promatranih zemalja. Također, kako bi analiza i tumačenje kretanja deviznog tečaja bilo što preciznije važno je raspolagati sa što više informacija o pojedinom gospodarstvu i o ključnim zbivanjima koja se ne mogu kvantificirati.

Već je prethodno spomenuto da na deviznom tržištu nije jednaka potražnja za svim konvertibilnim valutama (devizama). Dolar, euro, jen i funta najlikvidnije su valute jer je potražnja i ponuda na deviznom tržištu za njima stalna i stabilna. U narednim tablicama i grafikonu prikazana je značajnost navedene četiri valute po dnevnom prometu na OTC⁵⁴ tržištu.

	Total	Spot transactions	Outright forwards	Foreign exchange swaps	Currency swaps	FX options
Instrument, currency, counterparty and country	2016	2016	2016	2016	2016	2016
Total, "net-net" basis	5,067	1,652	700	2,378	82	254
By currency						
USD	4,438	1,385	600	2,160	74	218
EUR	1,591	519	178	807	22	64
JPY	1,096	395	151	458	18	74
GBP	649	211	92	305	10	30
AUD	348	143	41	138	7	20
CAD	260	105	34	103	4	14
CHF	243	57	30	150	2	5
CNY	202	68	28	86	3	18
SEK	112	34	13	59	1	5
Other currencies	1,195	388	232	490	23	61

Slika 11: OTC promet FX⁵⁵ instrumenata, travanj 2016

Izvor: BIS, https://www.bis.org/statistics/d11_1.pdf

Napomena: Dnevni prosjek u milijardama USD

Na slici 11 prikazan je promet pojedinih FX instrumenata po valutama u travnju 2016. godine. Najviše se trgovalo instrumentima u USD, čak 87,6% ukupnog prometa, slijedi EUR s 31,4% te JPY i GBP s 21,6% i 12,8% ukupnog prometa.

⁵⁴ OTC - overthecounter tržište

⁵⁵ FX - foreignexchange

Currency	2001		2004		2007		2010		2013		2016	
	Share	Rank	Share	Rank	Share	Rank	Share	Rank	Share	Rank	Share	Rank
USD	89.9	1	88.0	1	85.6	1	84.9	1	87.0	1	87.6	1
EUR	37.9	2	37.4	2	37.0	2	39.0	2	33.4	2	31.4	2
JPY	23.5	3	20.8	3	17.2	3	19.0	3	23.0	3	21.6	3
GBP	13.0	4	16.5	4	14.9	4	12.9	4	11.8	4	12.8	4


Slika 12: Distribucija valuta prema OTC FX prometu na neto-neto bazi⁵⁶

Izvor: BIS (2016): Triennial Central Bank Survey, Foreignexchange turnover in April 2016: <https://www.bis.org/publ/rpfx16fx.pdf>, str. 10.

Napomena: Zbog toga što su dvije valute uključene u svaku transakciju, zbroj svih postotnih udjela individualnih valuta nije 100%, nego 200%.

Slika 12 također prikazuje udjele pojedine valute u ukupnom prometu na OTC tržištu po odabranim godinama. U svim odabranim godinama USD ima najveći udio u prometu, s najmanjim udjelom - 84,9% u 2010. godini i najvećim udjelom u 2001. godini - 89,9%. Također, USD, EUR, JPY i GBP zauzimaju najveći obujam trgovanja u svakoj od navedenih godina.

Grafikon 1: OTC FX promet po valutnim parovima



Izvor: Izrada autorice

Grafikon 1 prikazuje da upravo tri valutna para (USD/EUR, USD/GBP i USD/JPY) koja su predmet ovog diplomskog rada i istraživanja zauzimaju najveće udjele u prometu OTC tržišta.

⁵⁶ Neto-neto baza - prilagođeno za lokalno i inozemno dvostruko prebrojavanje među trgovcima

Među navedenima u svim promatranim godinama najveći udio trgovanja zauzima valutni par USD/EUR.

3.1. Sjedinjene Američke Države

Sjedinjene Američke Države spadaju u sam svjetski vrh po gospodarskoj snazi, BDP u tekućim cijenama (lipanj 2017) iznosi 18 507 milijardi USD. Sama vrijednost američkog BDP-a (19 390 milijardi USD u prosincu 2017. godine) čini oko 31% svjetske ekonomije. Američko gospodarstvo je vrlo razvijeno i diversificirano s visokim stupnjem tehnološkog napretka i mnoštvom prirodnih bogatstava. Stopa nezaposlenosti iznosi 4%, dok stopa inflacije u lipnju 2018. iznosi 2,9%. SAD ima vanjsko trgovinski deficit u bilanci od 43053 miliona USD u svibnju 2018. godine.⁵⁷

Američki dolar u 20. stoljeću postao je vodeća i najvažnija svjetska valuta te ima ključnu ulogu u svjetskim monetarnim i financijskim odnosima. Prethodno je navedeno kako USD čini čak 87,6% ukupne trgovine na spot deviznom tržištu u travnju 2016. godine. Mnoge zemlje su tečajeve svojih valuta vezale za američki dolar i najveći dio svojih deviznih rezervi drže upravo u dolarima.⁵⁸

3.2. Euro zona

Eurozona je dio Europske Unije i čini je 19 od ukupno 28 zemalja članica koje su prihvatile euro kao svoju službenu valutu. Euro, kao valuta u upotrebi je od 1. siječnja 1999. godine, dok su novčanice i kovanice u optjecaj puštene 1. siječnja 2002. godine. Nakon SAD-a i Kine, Eurozona s 25% udjela (12 590 mlrd. USD) u ukupnom svjetskom BDP-u treća je ekonomska sila svijeta. BDP u tekućim cijenama u ožujku 2018. godine iznosio je 2 626 mlrd. EUR, odnosno 3 061 mlrd. USD. U lipnju 2018. godine inflacija je iznosila 2% što je i cilj ECB-a, dok je stopa nezaposlenosti iznosila 8,3%. Eurozona ima vanjskotrgovinski suficit od 19 250 mil. USD u svibnju 2018. godine. Euro čini 31,4% ukupne trgovine na spot deviznom tržištu u travnju 2016. godine.

⁵⁷TradingEconomics: United States, Indicators, raspoloživo na: <https://tradingeconomics.com/united-states/indicators>, [29.07.2018.]

⁵⁸Lovrinović, I. (2015): op.cit., str. 347.

3.3. Velika Britanija

Velika Britanija dio je Europske Unije no ne i Eurozone. Također od ožujka 2017. godine Velika Britanija pokrenula je postupak izlaska iz EU. Gospodarstvo Velike Britanije raspolaže bogatim ležištima zemnoga plina, te je također izvoznik nafte. U prosincu 2017. godine BDP Velike Britanije čini oko 5,3% (2 622 mlrd. USD) svjetske ekonomije. BDP u tekućim cijenama u ožujku 2018. godine iznosi 504 195 mil. USD, odnosno 660 mlrd. USD. Velika Britanija ostvaruje vanjskotrgovinski deficit od 3 655 mil. USD. Stopa nezaposlenosti u svibnju 2018. godine iznosi 4,2%, dok u lipnju iste godine stopa inflacije iznosi 2,4%. U travnju 2016. godine britanska funta četvrta je valuta po volumenu trgovanja s udjelom od 12,8%.

3.4. Japan

Japan je tek krajem 19. stoljeća otvorio svoja vrata suradnji s inozemnim zemljama. Japanske multinacionalne kompanije relativno su se brzo počele širiti i razvijati u inozemstvu. Možemo ga promatrati kao najveću svjetsku multinacionalnu kompaniju koja faktore potrebne za proizvodnju prikuplja diljem svijeta te ih finalizira i nadograđuje ih s „know-how“. Ova zemlja je kreator vlastite konkurentske pozicije te važan globalni inženjer.⁵⁹ Također, Japan nema niti jedan prirodni resurs koji bi mogao ponuditi svijetu, zbog nedostatka prirodnih bogatstava gotovo sve sirovine mora uvoziti (više od 90%). Tek je 1/7 površine u Japanu obradiva.


BDP Japanskog gospodarstva u tekućim cijenama u ožujku 2018. godine iznosi 533 911 mlrd. JPY, odnosno 4 806 mlrd. USD. BDP Japanskog gospodarstva čini oko 9,9% svjetskog BDP-a, a iznosi 4 872 mlrd. USD (prosina 2017. godine). Stopa nezaposlenosti u svibnju 2018. godine iznosila je 2,2%, Japan u vanjskoj trgovinskoj bilanci ima suficit od 6 491 mil. USD. Od 1990. godine, nakon stvaranja špekulativnog mjehura na tržištu dionica i nekretnina Japan se bori se deflacijom te se te godine nazivaju često „izgubljeno desetljeće“.⁶⁰ U lipnju 2018. godine stopa inflacije iznosi 0,7%.⁶¹ U travnju 2016. godine japanski jen treća je valuta po volumenu trgovanja s udjelom od 21,6%.

⁵⁹ Lovrinović, I. (2015): op.cit., str. 24.

⁶⁰ Tomić Z., (2014): Utjecaj makroekonomskih varijabli na spot devizno tržište, Diplomski rad, Ekonomski fakultet Zagreb, str. 22.

⁶¹ TradingEconomics: Japan, Indicators, raspoloživo na: <https://tradingeconomics.com/japan/indicators>, [29.07.2018.]

Kao jedna od nezavisnih varijabli utjecaja na kretanje deviznog tečaja pojavljuje se cijena nafte - WTI. Na sljedećoj slici prikazan je udio neto uvoza energije u potrošnji energije po zemljama od 2000. do 2015. godine.



Slika 13: Uvoz energije, neto (% od potrošnje energije)

Izvor: World Bank: Energy imports, net (% of energy use): <https://data.worldbank.org/indicator/EG.IMP.CON.S.ZS?contextual=default&end=2015&locations=JP-US-GB-XC&start=2000&view=chart>

Neto uvoz energije izračunat je kao potrošnja energije minus proizvodnja. Oboje je mjereno u ekvivalentima nafte. Negativna vrijednost upućuje da je zemlja neto izvoznik, dok pozitivna vrijednost upućuje na neto uvoznika. Dakle, iz ove slike može se zaključiti da su od navedenih zemalja Japan i Eurozona daleko najovisnije o uvozu nafte.

4. EMPIRIJSKO ISTRAŽIVANJE UTJECAJA DETERMINANTI NA KRETANJE DEVIZNOG TEČAJA

U ovom poglavlju definirat će se statistički skup istraživanja, navesti koji se podaci koriste za pojedine varijable te će se predstaviti metodologija pomoću koje će se provesti istraživanje. Na kraju poglavlja prezentirat će se rezultati provedenog istraživanja.

Predmet ovog istraživanja je analiza utjecaja determinanti na kretanje tečaja parova najvažnijih svjetskih valuta u razdoblju od 2002. do 2017. godine. Iz predmeta ovog istraživanja proizlazi definicija statističkog skupa, koji obuhvaća tečaj pojedinog valutnog para (USD/EUR, USD/GBP i USD/JPY) u razdoblju od 2002. do 2017. godine. Navedeno razdoblje odabrano je s početkom u 2002. godini iz razloga što su 1. siječnja 2002. godine novčanice i kovanice eura puštene u optjecaj. Kao domaća valuta u istraživanju promatrat će se američki dolar - USD.

4.1. Podaci i metodologija istraživanja

Kako bi se došlo do spoznaje ovisi li pojedini devizni tečaj o različitim varijablama, bit će provedena multipla, odnosno višestruka regresija u kojoj jedna zavisna varijabla ovisi o $k \geq 2$ nezavisnih varijabli. Za provedbu regresijske analize bit će korišten statistički paket SPSS (StatisticalPackage for theSocialSciences).

Model višestruke regresije je algebarski model kojim se analitički određuje statistička povezanost jedne zavisne numeričke varijable (regresand) s dvije ili više nezavisnih numeričkih varijabli (regresorskih varijabli). Model višestruke regresije upotrebljuje se zbog pretpostavke o linearnoj povezanosti između jedne zavisne varijable i skupa nezavisnih varijabli. Opći oblik modela glasi: ⁶²

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 + \hat{\beta}_2 \cdot X_2 + \dots + \hat{\beta}_k \cdot X_k + e(10)$$

\hat{Y} - zavisna varijabla,

X_1, X_2, \dots, X_k - nezavisne varijable,

$\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k$ - parametri koji se procjenjuju,

e - slučajna greška.

Za ocjenjivanje parametara koristit će se ENTER metoda što znači da sve varijable prilikom ocjenjivanja u model višestruke regresije ulaze odjednom.

⁶²Jurun, E. (2007.): Nastavni materijali kolegija „Kvantitativne metode u ekonomiji“, Ekonomski fakultet Split, str. 36.

Ovako definiran model ima sljedeće pretpostavke.⁶³

Homoskedastičnost - varijanca reziduala je konstantna i konačna, odnosno reziduali su distribuirani neovisno o regresorskim varijablama. U SPSS-u ova pretpostavka ispitat će se pomoću značajnosti Spearmanovog koeficijenta korelacije ranga između apsolutnih vrijednosti reziduala i regresorskih varijabli.

Normalnost - reziduali su normalno distribuirani s očekivanjem jednakim 0. Ispitat će se pomoću histograma ili iz grafikona na kojem su ucrtane vrijednosti opaženih i očekivanih vrijednosti kada bi reziduali bili normalno distribuirani (Normal P-P Plot of Regression Standardized Residual).

Nezavisnost 1 - rezidualna odstupanja međusobno su nezavisna, ispituje se problem postojanja autokorelacije. Numerički test (Durbin Watson) koristit će se za uočavanje problema autokorelacijereziduala. DW test veličina uspoređuje se s kritičnim vrijednostima d_L i d_U koje se za zadanu razinu signifikantnosti (α), veličinu uzorka (n), i broj regresorskih varijabli (k) očitavaju iz tablica za Durbin-Watsonov test. Ukoliko je dobivena empirijska vrijednost blizu 2, u modelu ne postoji problem autokorelacijereziduala. Vrijednost blizu 0 upućuje na pozitivnu autokorelaciju, dok vrijednost blizu 4 upućuje na negativnu autokorelacijereziduala.

Nezavisnost 2 - regresorske varijable su međusobno nezavisne, ispituje se problem multikolinearnosti. Za uočavanje problema multikolinearnosti između regresorskih varijabli koristit će se faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL), problem multikolinearnosti je prisutan kada je $VIF_j > 5$, odnosno $TOL_j < 0,2$.

Kao determinante utjecaja promatrat će se sljedeće varijable na temelju mjesečnih podataka: promjena razlike između domaće i inozemne inflacije, domaće i inozemne kamatne stope, domaće i inozemne razine dohotka (mjerene indeksom industrijske proizvodnje), VIX indeks rizičnosti, kretanje cijene nafte te Consumer Confidence Index (CCI). Očekivani utjecaj svake od navedenih varijabli objašnjen je u poglavlju 1.2. Ciljevi i hipoteze istraživanja.

Kao zavisna varijabla u ovom radu uzet je tečaj tri valutna para (USD/EUR, USD/GBP i USD/JPY), mjesečni podaci za navedeno razdoblje uzeti su sa stranice IMF-a (International Monetary Fund). Podaci su preuzeti kao mjesečni prosjek vrijednosti nacionalnih valuta po američkom dolaru. Kao mjera inflacije uzet je (H)CPI indeks, dok je za kamatnu stopu uzeta kratkoročna kamatna stopa na *treasury bills*, za navedene nezavisne varijable

⁶³ Pivac, S. (2010.): E-nastavni materijali kolegija „Statističke metode“, Ekonomski fakultet Split, str. 301.-335.

podaci su uzeti s OECD-a. Podaci o BDP-u za pojedinu državu izdaju se na kvartalnim, ne na mjesečnim razinama pa je kao proxy varijabla za BDP uzet IIP indeks. Prosječni mjesečni izgladeni podaci o IIP indeksu uzeti su sa stranice IMF-a. Sljedeća nezavisna varijabla - cijena nafte kvantificirana preko WTI indeksa, podaci su preuzeti sa stranice FRED-a (Federal Reserve Bank of St. Louis). VIX indeks uzet je kao varijabla rizičnosti, volatilnosti CBOE, a podaci su preuzeti s FRED-a. Posljednja nezavisna varijabla odnosi se na CCI indeks povjerenja potrošača prema određenoj ekonomiji, prosječni mjesečni podaci preuzeti su sa stranica OECD-a.⁶⁴

4.2. Utjecaj determinanti na kretanje tečaja USD/EUR

Utjecaj navedenih varijabli će se pomoću višestruke regresije prvo pokazati na valutnom paru USD/EUR.

Oblik modela:

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 + \hat{\beta}_2 \cdot X_2 + \hat{\beta}_3 \cdot X_3 + \hat{\beta}_4 \cdot X_4 + \hat{\beta}_5 \cdot X_5 + \hat{\beta}_6 \cdot X_6 + e \quad (11)$$

\hat{Y} - postotna promjena vrijednosti dolara

X_1 - postotna promjena vrijednosti cijene nafte

X_2 - razlika između postotnih promjena američke i europske razine inflacije

X_3 - razlika između postotnih promjena američke i europske razine dohotka

X_4 - postotna promjena indeks rizičnosti

X_5 - razlika između postotnih promjena američkog i europskog indeksa povjerenja potrošača

X_6 - razlika između postotnih promjena američke i europske razine kamatnih stopa

$\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_6$ - parametri koji se procjenjuju

e - slučajna greška

U tablici 2 prikazane su odabrane nezavisne varijable, njihove oznake u modelu te su prezentirani očekivani utjecaji pojedine varijable na kretanje zavisne varijable - tečaja. Razlog pozitivnog/negativnog utjecaja pojedine nezavisne varijable prezentiran je kroz objašnjenje hipoteza ovog rada.

⁶⁴ Napomena: Svi navedeni podaci su pretvoreni u postotne promjene kroz vrijeme te su tako korišteni za input u sva tri modela.

Tablica 2: Prikaz očekivanog utjecaja varijabli na zavisnu varijablu - postotna promjena vrijednosti dolara (valutni par USD/EUR)

Varijable utjecaja	Indikator	Oznaka	Očekivani utjecaj
Postotna promjena vrijednosti cijene nafte	WTI	OIL	+
Razlika između postotnih promjena američke i europske razine inflacije	(Harmonizirani) indeks potrošačkih cijena	INF	-
Razlika između postotnih promjena američke i europske razine dohotka	Indeks industrijske proizvodnje	IIP	+/-
Postotna promjena indeks rizičnosti	VIX mjera volatilnosti S&P 500 indeksa	VIX	+
Razlika između postotnih promjena američkog i europskog indeksa povjerenja potrošača	Indeks povjerenja potrošača	CCI	+
Razlika između postotnih promjena američke i europske razine kamatnih stopa	Kratkoročna kamatna stopa na <i>treasury bills</i>	INT	+

Izvor: Izrada autorice

U programu SPSS ubačene su vrijednosti za svaku varijablu te je proveden postupak višestruke linearne regresije. Potrebno je napomenuti da kako bi mogli donijeti zaključke na temelju modela višestruke regresije potrebno je da model ispuni prethodno navedene četiri pretpostavke. Sljedeća tablica prikazuje dva regresijska modela za valutni par USD/EUR, postojanje dva regresijska modela bit će objašnjeno u nastavku.

Prvi regresijski model - Model 1a nije zadovoljio treću pretpostavku o ne postojanju autokorelacije. Kao što možemo vidjeti u tablici 3 DW test veličina⁶⁵ za ovaj model iznosi 1,605. Prema tablicama kritičnih vrijednosti (Prilog 1), problem autokorelacije ne postoji, za $n=191$ i $k=6$, kada je DW test veličina $> (d_u)$, odnosno 1,82. Kako bi se riješio problem autokorelacije, uvela se zavisna varijabla s pomakom ($t-1$), kao sedma nezavisna varijabla. Dakle, Model 1b sadrži sedam nezavisnih varijabli u razdoblju od ožujka 2002. godine do prosinca 2017. godine, ukupno 190 opažanja. Uvođenjem zavisne varijable s pomakom problem autokorelacije više ne postoji, DW test veličina u Modelu 1b iznosi 1,982 što je veće od kritične vrijednosti iz DW tablica za $n=190$ i $k=7$. Dakle, $1,982 > (d_u)$, odnosno 1,84. Preostale tri pretpostavke, također su zadovoljene Modelom 1b te će biti prezentirane naknadno.

⁶⁵ Napomena: U radu je korištena razina signifikantnosti - $\alpha=0,05$

Tablica 3: Rezultati provedene regresijske analize za valutni par USD/EUR

Varijabla	Model 1a	Model 1b
Constant	-0,001 (0,002)	-0,001 (0,002)
OIL	-0,074*** (0,020)	-0,065*** (0,020)
INF	0,015 (0,359)	0,186 (0,355)
IIP	0,120 (0,161)	0,115 (0,157)
VIX	0,013 (0,010)	0,012 (0,009)
CCI	1,206 (0,707)	0,959 (0,695)
INT	0,004 (0,006)	0,001 (0,006)
USD/EUR t-1	-	0,226*** (0,071)
F test	4,705***	5,686***
Koeficijent determinacije	0,133	0,180
Standardna pogreška	0,0223	0,0218
DW	1,605	1,982

Izvor: Izrada autorice

Napomena: ***, ** i * označavaju signifikantnost na razini 1%, 5% i 10% značajnosti, standardne pogreške parametara su dane u zagradama.

Sljedeća, tablica 4 daje prikaz konačnog regresijskog modela za USD/EUR koji se sastoji od 7 regresorskih varijabli, koje su odjednom ušle u model - ENTER metoda. Dakle, u odnosu na jednadžbu (11) u ovoj regresiji dodana je još nezavisna varijabla X_7 s pripadajućim parametrom - $\hat{\beta}_7$.

Tablica 4: Enter metoda - Model 1b - valutni par USD/EUR

Variables Entered/Removed ^a			
Model	Variables Entered	Variables Removed	Method
1	USD/EUR t-1, VIX, IIP, INT, CCI, INF, OIL ^b	.	Enter

a. Dependent Variable: USD/EUR

b. All requested variables entered.

Izvor: Izrada autorice

Nakon utvrđivanja ne postojanja autokorelacije, ispitat će se i preostale tri pretpostavke te će ukoliko su sve pretpostavke ispunjene ići s analizom regresijskog Modela 1b.

Prva pretpostavka - ispitivanje problema heteroskedastičnosti varijance reziduala ispitat će se pomoću Spearmanovog koeficijenta korelacije ranga između apsolutnih vrijednosti reziduala i izabranih regresorskih varijabli. Kod ovog testa najprije se postavljaju sljedeće hipoteze:

$$H_0 \dots r_s = 0$$

$$H_1 \dots r_s \neq 0$$

H_0 - početna hipoteza, ne postoji problem heteroskedastičnosti varijance reziduala u ocijenjenom modelu, odnosno vrijednost Spearmanovog koeficijenta korelacije ranga između regresorske varijable i apsolutnih reziduala jednaka je 0.

H_1 - postoji problem heteroskedastičnosti varijancereziduala, odnosno vrijednost Spearmanovog koeficijenta korelacije ranga između regresorske varijable i apsolutnih reziduala različit je od 0.

Correlations			OIL	INF	IIP	VIX	CCI	INT	USD/EUR t-1	absres
Spearman's rho	OIL	Correlation Coefficient	1,000	,173*	-,035	-,101	-,200**	-,083	-,124	-,090
		Sig. (2-tailed)	.	,017	,636	,165	,006	,254	,088	,218
		N	190	190	190	190	190	190	190	190
	INF	Correlation Coefficient	,173*	1,000	-,161*	,089	-,293**	-,184*	-,188**	-,094
		Sig. (2-tailed)	,017	.	,026	,224	,000	,011	,010	,195
		N	190	190	190	190	190	190	190	190
	IIP	Correlation Coefficient	-,035	-,161*	1,000	,040	,069	,069	,065	-,035
		Sig. (2-tailed)	,636	,026	.	,580	,344	,347	,373	,630
		N	190	190	190	190	190	190	190	190
	VIX	Correlation Coefficient	-,101	,089	,040	1,000	-,148*	,096	-,008	-,036
		Sig. (2-tailed)	,165	,224	,580	.	,041	,186	,915	,619
		N	190	190	190	190	190	190	190	190
	CCI	Correlation Coefficient	-,200**	-,293**	,069	-,148*	1,000	,179*	,212**	,148*
		Sig. (2-tailed)	,006	,000	,344	,041	.	,014	,003	,041
		N	190	190	190	190	190	190	190	190
	INT	Correlation Coefficient	-,083	-,184*	,069	,096	,179*	1,000	,342**	,093
		Sig. (2-tailed)	,254	,011	,347	,186	,014	.	,000	,203
		N	190	190	190	190	190	190	190	190
	USD/EUR t-1	Correlation Coefficient	-,124	-,188**	,065	-,008	,212**	,342**	1,000	,075
		Sig. (2-tailed)	,088	,010	,373	,915	,003	,000	.	,305
		N	190	190	190	190	190	190	190	190
	absres	Correlation Coefficient	-,090	-,094	-,035	-,036	,148*	,093	,075	1,000
		Sig. (2-tailed)	,218	,195	,630	,619	,041	,203	,305	.
		N	190	190	190	190	190	190	190	190

*. Correlation is significant at the 0.05 level (2-tailed).

**. Correlation is significant at the 0.01 level (2-tailed).

Slika14: Spearmanovi koeficijenti korelacije - valutni par USD/EUR

Izvor: Izrada autorice


Iz ove slike može se vidjeti empirijska signifikantnost koeficijenata korelacije:

$\alpha^*_1 = 0,218, \alpha^*_2 = 0,195, \alpha^*_3 = 0,630, \alpha^*_4 = 0,619, \alpha^*_5 = 0,041, \alpha^*_6 = 0,203$ i $\alpha^*_7 = 0,305$.

Vrijednosti (α^*) u šest od sedam slučajeva veća je od 5%, samo je kod varijable CCI ona manja od 5%, no kako navedena varijabla nije statistički značajna (Tablica 3) i kako $\alpha^*_5 = 0,041$ ne odstupa puno od 5% prihvaća se nulta hipoteza da korelacija nije statistički značajna. Dakle, može se zaključiti da u modelu ne postoji problem heteroskedastičnosti varijance reziduala.

Kako bi se provjerila druga pretpostavka - Normalnost, koristit će se histogram standardiziranih reziduala i P-P grafikon normalno distribuiranih reziduala.


Grafikon 2: Histogram standardiziranih reziduala - valutni par USD/EUR



Izvor: Izrada autorice

Prema grafikonu 2, može se vidjeti da su reziduali normalno distribuirani s očekivanjem jednakim nuli i standardnom devijacijom približno jednakom jedinici. Također, isto se može zaključiti iz grafikona 3.

Grafikon 3: P-P grafikon normalno distribuiranih reziduala - valutni par USD/EUR



Izvor: Izrada autorice

Posljednja pretpostavka koju je potrebno ispitati je postojanje multikolinearnosti nezavisnih varijabli. Potvrdu o ne postojanju daju vrijednosti faktora inflacije varijance (VIF_j), i njihove recipročne vrijednosti (TOL_j) prezentirane na sljedećoj slici:

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
	B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
1 (Constant)	-,001	,002		-,386	,700	-,004	,003		
OIL	-,065	,020	-,239	-3,285	,001	-,104	-,026	,852	1,173
INF	,186	,355	,037	,523	,602	-,515	,886	,890	1,124
IIP	,115	,157	,051	,732	,465	-,195	,425	,946	1,057
VIX	,012	,009	,092	1,296	,196	-,006	,031	,898	1,114
CCI	,959	,695	,098	1,379	,169	-,413	2,330	,884	1,131
INT	,001	,006	,011	,160	,873	-,010	,012	,939	1,065
USD/EUR t-1	,226	,071	,226	3,168	,002	,085	,367	,883	1,133

a. Dependent Variable: USD/EUR

Slika 15: Faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL) - valutni par USD/EUR

Izvor: Izrada autorice

Može se prihvatiti pretpostavka o ne postojanju multikolinearnosti, jer su za sve parametre regresije faktori inflacije varijance manji od 5, a postotak tolerancije je veći od 20%.

Nakon što su se provjerile sve navedene pretpostavke modela višestruke regresije i nakon zaključka da iste ispunjavanju postavljene kriterije može se ići na analizu konačnog regresijskog modela - Model 1b.

Iako model kao cjelina nije predmet ovoga istraživanja, već utjecaj pojedinih varijabli, objasniti će se temeljni pokazatelji ovog modela. Koeficijent determinacije iznosi 0,180, odnosno 18.0%, što upućuje na lošu reprezentativnost modela kao cjeline, inače ovaj pokazatelj mora biti veći od 70%, da bi model bio reprezentativan. Također F - test iznosi 5,686 te je pri razini signifikantnosti od 1% Model 1b statistički značajan.

Što se tiče utjecaja pojedinih nezavisnih varijabli na zavisnu varijablu, kao značajne pokazale su se samo cijena nafta i zavisna varijabla s pomakom. Obe navedene varijable značajne su pri signifikantnosti od 1%. (Tablica 3).

Pokazalo se da zavisna varijabla s pomakom ima značajan pozitivan utjecaj ($\hat{\beta}_7 = 0,226$) na kretanje promjene tečaja USD/EUR, dakle ako je npr. tečaju prethodnom razdoblju rastao, očekuje se da će u sljedećem razdoblju on također rasti i obrnuto. Navedeno je i očekivano jer ako „cijena“ bilo koje „imovine“ pa tako i tečaja raste u jednom razdoblju, možemo očekivati uzlaznu putanju i dalje, ako su ostale varijable utjecaja nepromijenjene.

Postotna promjena cijene nafte (OIL) u ocijenjenom regresijskom modelu - Model 1b pokazuje negativan utjecaj na postotnu promjenu tečaja USD/EUR. Iz prethodno objašnjenih utjecaja varijabli pa tako i cijene nafte iz poglavlja 1.2., očekivao se pozitivan utjecaj cijene nafte na vrijednost američkog dolara jer države Eurozone više ovise o uvozu nafte nego SAD-e (Slika13). Prema tome, kada cijena nafte raste, članice Eurozone trebaju platiti više dolara po jednom barelu, samim time potražnja za američkim dolarom raste, te u konačnici dovodi do povećane razmjene eura za dolar i deprecijacije eura, odnosno aprecijacije dolara i rasta zavisne varijable.

Ovaj suprotan utjecaj cijene nafte na vrijednost američkog dolara u valutnom paru USD/EUR prezentiran u Modelu 1b, može se pokušati objasniti kroz tržišne trendove i očekivanja. Naime, naš model predstavlja razdoblje od 2002. do 2017. godine. U navedenom razdoblju, došlo je do uvođenja eura 1. siječnja 2002. godine. Već 1999. godine, prije službenog uvođenja eura, ekonomisti su raspravljali o mogućem utjecaju nove valute - eura na položaj američkog dolara u svijetu. S obzirom na mnoge pozitivne strane uvođenja eura (smanjenje transakcijskih troškova, razvijanje europskih financijskih tržišta, itd.), vrijednost američkog dolara bi trebala pasti. Nakon što je 1. siječnja 2002. godine uveden euro, dolar je

kontinuirano deprecirao u odnosu na euro⁶⁶. Daljnjoj deprecijaciji pridonijela je i pozitivna percepcija eura te činjenica da su Japanska banka i FED koristili euro u zamjenu za dolar kako bi diversificirali devizne rezerve. Do 2008. godine euro je kontinuirano aprecirao u odnosu na dolar.


Dugoročni pad dolara odgovara rastućoj putanji cijene sirove nafte u istom razdoblju (naravno izuzev svjetske financijske krize od 2007. do 2009. godine). Mnoge studije (Büyüksahin and Harris 2011; Cifarelli and Paladino 2010; Fattouh and Scaramozzino 2011; Erten and Ocampo 2012) su pokazale da razlog tzv. „super cycle-a“ cijene sirove nafte, nisu samo povećanje potražnje zemalja u razvoju, globalne monetarne politike popuštanja, financijske špekulacije veći i sama očekivanja da će cijena nafte i dalje rasti. Kako su tržišni trendovi i očekivanja pokazivala uzlaznu cijenu nafte i padajuću vrijednost dolara, bilo je logično da će investitori promatrajući naftu i dolar kao dvije vrste „imovine“ u svom portfoliju zauzeti long poziciju sirove nafte i short poziciju u trgovanju američkim dolarom kako bi ostvarili „hedging“. Navedeno je dovelo do negativne koreliranosti cijene nafte i dolara u ovom razdoblju. Iako su se smjerovi kretanja cijene nafte i američkog dolara nakon krize promijenili, strategija „hedginga“ i dalje postoji pa tako i negativna korelacija između ove dvije varijable.⁶⁷

Grafikon 4 prikazuje negativnu vezu između USD/EUR i WTI - cijene sirove nafte. Lijeva vertikalna os odnosi se na vrijednosti samog tečaja USD/EUR, dok desna os prikazuje vrijednosti koje se odnose na cijenu nafte - WTI.

⁶⁶ Napomena: Ako promatramo dolarov indeks, euro ima ponder oko 57,6% ukupne vrijednosti dolara .

⁶⁷ Liao, J., Shi, Y., Xu, X.: Why Is the Correlation between Crude Oil Prices and the US Dollar Exchange Rate Time-Varying?— Explanations Based on the Role of Key Mediators, International Journal of Financial Studies, June 2018, str 6-7.

Grafikon 4: Kretanje tečaja USD/EUR i cijene nafte - WTI u razdoblju od siječnja 2002. do prosinca 2017. godine



Izvor: Izrada autorice

Prethodno u radu je navedeno da će se nezavisna varijabla - kamatna stopa uključiti pomoću vrijednosti kratkoročne kamatne stope. Za valutni par USD/EUR u Modelu 1b kao značajna nije se pokazala varijabla razlika promjena u kratkoročnim kamatnim stopama između SAD-e i Eurozone. Kako je to jedna od varijabli čiji se značajni utjecaj posebno očekivao u sljedećem regresijskom modelu će umjesto kratkoročnih kamatnih stopa biti uvrštene dugoročne kamatne stope na državne obveznice.

U početnom Modelu 1c također je postojalo problem autokorelacije pa je uključena zavisna varijabla s pomakom i dobiven je konačni regresijski model s dugoročnim kamatnim stopama - Model 1d. Za cjelokupne specifikacije modela i ispunjavanje četiri pretpostavke višestruke regresije (Prilog 2).

Tablica 5: Rezultati provedene regresijske analize za valutni par USD/EUR (umjesto kratkoročnih k.s. korištene su dugoročne.s.)

Varijabla	Model 1c	Model 1d
Constant	-0,001 (0,002)	-0,001 (0,002)
OIL	-0,076*** (0,020)	-0,069*** (0,019)
INF	0,078 (0,353)	0,249 (0,349)
IIP	0,086 (0,158)	0,087 (0,154)
VIX	0,019** (0,010)	0,017* (0,009)
CCI	1,362** (0,691)	1,070 (0,680)
INT	0,055*** (0,020)	0,053*** (0,020)
USD/EUR t-1	-	0,220*** (0,069)
F test	6,02***	6,928***
Koeficijent determinacije	0,164	0,210
Standardna pogreška	0,0219	0,0214
DW	1,535	1,926

Izvor: Izrada autorice

Prilikom zamjene kratkoročnih s dugoročnim kamatnim stopama značajnost i negativan/pozitivan utjecaj nafte/zavisne varijable s pomakom pri signifikantnosti od 1% ostaju nepromijenjeni.⁶⁸ Kao nove značajne varijable utjecaja pojavljuju se kamatna stopa i VIX indeks rizičnosti.

Razlike u promjenama dugoročnih kamatnih stopa između SAD-a i Eurozone očekivano imaju pozitivan utjecaj na vrijednost američkog dolara (aprecijacija dolara). Dakle, ukoliko dođe do situacije da kamatne stope (dugoročne) u SAD-u porastu, dok one u Eurozoni ostanu nepromijenjene ili relativno narastu manje, očekuje se da će investitori svoja sredstva usmjeravati na investicije u američki dolar. Dakle, potražnja za američkim dolarom porast će, dok će se istovremeno povećati ponuda eura, u konačnici navedeno vodi aprecijaciji dolara u odnosu na euro, što pokazuje i predznak uz varijablu INT ($\hat{\beta}_6 = 0,053$) u Modelu 1d.

⁶⁸ Napomena: Utjecaj navedenih varijabli objašnjen je prethodno.

Utjecaj VIX indeksa rizičnosti u Modelu 1d značajan je i pozitivan ($\hat{\beta}_4 = 0,017$), kako se i očekivalo. Negativan utjecaj VIX indeksa očekivan je jer kada VIX bilježi visoke vrijednosti znači da averzija rizika investitora na financijskom tržištu raste, što upućuje na to da će oni svoja sredstva usmjeravati na manje rizične investicije. Investitori će prodavati visoko rizične vrijednosne papire i okrenuti se ka sigurnijim investicijama, kao što su vrijednosnice američke vlade. Navedeno ima pozitivan utjecaj na tečaj USD/EUR, odnosno američki dolar u odnosu na euro aprecira.

4.3. Utjecaj determinanti na kretanje tečaja USD/GBP

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 + \hat{\beta}_2 \cdot X_2 + \hat{\beta}_3 \cdot X_3 + \hat{\beta}_4 \cdot X_4 + \hat{\beta}_5 \cdot X_5 + \hat{\beta}_6 \cdot X_6 + e \quad (12)$$

\hat{Y} - postotna promjena vrijednosti dolara

X_1 - postotna promjena vrijednosti cijene nafte

X_2 - razlika između postotnih promjena američke i britanske razine inflacije

X_3 - razlika između postotnih promjena američke i britanske razine dohotka

X_4 - postotna promjena indeks rizičnosti

X_5 - razlika između postotnih promjena američkog i britanskog indeksa povjerenja potrošača

X_6 - razlika između postotnih promjena američke i britanske razine kamatnih stopa

$\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_6$ - parametri koji se procijenjuju

e - slučajna greška

U tablici 6 prikazane su odabrane nezavisne varijable, njihove oznake u modelu te su prezentirani očekivani utjecaji pojedine varijable utjecaja na kretanje zavisne varijable - tečaja. Razlog pozitivnog/negativnog utjecaja pojedine nezavisne varijable prezentiran je već u dijelu hipoteza ovog rada.

U programu SPSS proveden je postupak višestruke linearne regresije s napomenom da kako bi mogli donijeti zaključke na temelju modela višestruke regresije potrebno je da model ispuni prethodno navedene četiri pretpostavke. Sljedeća tablica daje prikaz dva regresijska modela za valutni par USD/GBP.

Tablica 6: Prikaz očekivanog utjecaja varijabli na zavisnu varijablu - postotna promjena vrijednosti dolara (valutni par USD/GBP)

Varijable utjecaja	Indikator	Oznaka	Očekivani utjecaj
Postotna promjena vrijednosti cijene nafte	WTI	OIL	+
Razlika između postotnih promjena američke i britanske razine inflacije	(Harmonizirani) indeks potrošačkih cijena	INF	-
Razlika između postotnih promjena američke i britanske razine dohotka	Indeks industrijske proizvodnje	IIP	+/-
Postotna promjena indeksa rizičnosti	VIX mjera volatilnosti S&P 500 indeksa	VIX	+
Razlika između postotnih promjena američkog i britanskog indeksa povjerenja potrošača	Indeks povjerenja potrošača	CCI	+
Razlika između postotnih promjena američke i britanske razine kamatnih stopa	Kratkoročna kamatna stopa na <i>treasury bills</i>	INT	+

Izvor : Izrada autorice

Kao i kod valutnog para USD/EUR prvi regresijski model - Model 2a nije zadovoljavao treću pretpostavku o ne postojanju autokorelacije. DW test veličina prvog modela iznosi 1,82 (Tablica 7), dok prema tablicama DW testa (Prilog 1), treba biti veća od (d_u), odnosno 1,83 kako problem autokorelacije ne bi bio prisutan. Kako bi se riješio problem autokorelacije, uvodi se zavisna varijabla s pomakom ($t-1$), kao sedma nezavisna varijabla. Dakle, Model 1b sadrži sedam nezavisnih varijabli u razdoblju od ožujka 2002. godine do prosinca 2017. godine, ukupno 190 opažanja. Uvođenjem zavisne varijable s pomakom problem autokorelacije više ne postoji, DW test veličina u Modelu 2b iznosi 2,169 što je veće od kritične vrijednosti iz DW tablica za $n=190$ i $k=7$. Dakle, $2,169 > (d_u)$, odnosno 1,84.

Sljedeća, tablica 8 daje prikaz konačnog regresijskog modela za USD/GBP koji se sastoji od 7 regresorskih varijabli, koje su odjednom ušle u model ENTER metodom. Dakle, u odnosu na jednadžbu (12) u ovoj regresiji dodana je još nezavisna varijabla X_7 s pripadajućim parametrom - $\hat{\beta}_7$.

Tablica 7: Rezultati provedene regresijske analize za valutni par USD/GBP

Varijabla	Model 2a	Model 2b
Constant	0,001 (0,002)	0,001 (0,002)
OIL	-0,078*** (0,021)	-0,070*** (0,021)
INF	-0,255 (0,371)	-0,173 (0,368)
IIP	-0,086 (0,144)	-0,082 (0,142)
VIX	0,010 (0,010)	0,011 (0,010)
CCI	0,526 (0,613)	0,406 (0,606)
INT	0,022* (0,013)	0,020* (0,013)
USD/GBP t-1	-	0,183*** (0,069)
F test	5,960***	6,283***
Koeficijent determinacije	0,163	0,195
Standardna pogreška	0,0218	0,0215
DW	1,823	2,169

Izvor: Izrada autorice

Napomena: ***, ** i * označavaju signifikantnost na razini 1%, 5% i 10% značajnosti, standardne pogreške parametara su dane u zagradama.

Tablica 8: Enter metoda - Model 2b - valutni par USD/GBP

Variables Entered/Removed ^a			
Model	Variables Entered	Variables Removed	Method
1	USD/GBP t-1, VIX, IIP, INF, CCI, INT, OIL ^b	.	Enter

a. Dependent Variable: USD/GBP

b. All requested variables entered.

Izvor: Izrada autorice

Nakon utvrđivanja ne postojanja autokorelacije, ispitat će se i preostale tri pretpostavke te će ukoliko su sve pretpostavke ispunjene ići s analizom regresijskog Modela 2b.

Ispitivanje problema heteroskedastičnosti varijance reziduala ispitat će se pomoću Spearmanovog koeficijenta korelacije ranga između apsolutnih vrijednosti reziduala i izabranih regresorskih varijabli. Hipoteze ovog testa navedene su prethodno u radu za valutni par USD/EUR te iste vrijede i u ovom slučaju.

Correlations			OIL	INF	IIP	VIX	CCI	INT	USD/GBP t-1	absres
Spearman's rho	OIL	Correlation Coefficient	1,000	,332**	,063	-,101	-,163*	-,155*	-,034	-,026
		Sig. (2-tailed)	.	,000	,385	,165	,024	,033	,639	,722
		N	190	190	190	190	190	190	190	190
	INF	Correlation Coefficient	,332**	1,000	,057	,086	-,266**	-,182*	-,090	-,099
		Sig. (2-tailed)	,000	.	,431	,236	,000	,012	,218	,173
		N	190	190	190	190	190	190	190	190
	IIP	Correlation Coefficient	,063	,057	1,000	,110	,015	,039	,011	-,070
		Sig. (2-tailed)	,385	,431	.	,131	,840	,590	,876	,339
		N	190	190	190	190	190	190	190	190
	VIX	Correlation Coefficient	-,101	,086	,110	1,000	-,211**	,166*	-,141	-,001
		Sig. (2-tailed)	,165	,236	,131	.	,003	,022	,053	,989
		N	190	190	190	190	190	190	190	190
	CCI	Correlation Coefficient	-,163*	-,266**	,015	-,211**	1,000	,050	,092	,018
		Sig. (2-tailed)	,024	,000	,840	,003	.	,497	,209	,808
		N	190	190	190	190	190	190	190	190
	INT	Correlation Coefficient	-,155*	-,182*	,039	,166*	,050	1,000	,043	,001
		Sig. (2-tailed)	,033	,012	,590	,022	,497	.	,557	,993
		N	190	190	190	190	190	190	190	190
	USD/GBP t-1	Correlation Coefficient	-,034	-,090	,011	-,141	,092	,043	1,000	,060
		Sig. (2-tailed)	,639	,218	,876	,053	,209	,557	.	,410
		N	190	190	190	190	190	190	190	190
	absres	Correlation Coefficient	-,026	-,099	-,070	-,001	,018	,001	,060	1,000
		Sig. (2-tailed)	,722	,173	,339	,989	,808	,993	,410	.
		N	190	190	190	190	190	190	190	190

** . Correlation is significant at the 0.01 level (2-tailed).

* . Correlation is significant at the 0.05 level (2-tailed).

Slika 16: Spearmanovi koeficijenti korelacije - valutni par USD/GBP

Izvor: Izrada autorice


Iz slike 16 može se vidjeti empirijska signifikantnost koeficijenata korelacije sa sljedećim vrijednostima:

$$\alpha^*_1 = 0,722, \alpha^*_2 = 0,173, \alpha^*_3 = 0,339, \alpha^*_4 = 0,989, \alpha^*_5 = 0,808, \alpha^*_6 = 0,993 \text{ i } \alpha^*_7 = 0,410.$$

Vrijednosti (α^*) u svim slučajevima veće su od 5%. Stoga se prihvaća nulta hipoteza da korelacija nije statistički značajna. Dakle, može se zaključiti da u modelu ne postoji problem heteroskedastičnosti varijance reziduala.


Za provjeru druge pretpostavke - Normalnosti, koristit će se histogram standardiziranih reziduala i P-P grafikon normalno distribuiranih reziduala. Prema grafikonima 5 i 6 može se vidjeti da su reziduali normalno distribuirani s očekivanjem jednakim nuli i standardnom devijacijom približno jednakom jedinici.

Grafikon 5: Histogram standardiziranih reziduala - valutni par USD/GBP



Izvor: Izrada autorice

Grafikon 6: P-P grafikon normalno distribuiranih reziduala- valutni par USD/GBP



Izvor: Izrada autorice

Posljednja pretpostavka koju je potrebno ispitati je postojanje multikolinearnosti nezavisnih varijabli. Potvrdu o ne postojanju daju vrijednosti faktora inflacije varijance (VIF_j), i njihove recipročne vrijednosti (TOL_j), prezentirane na sljedećoj slici:

Coefficients ^a									
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
	B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
1 (Constant)	,001	,002		,463	,644	-,002	,004		
OIL	-,070	,021	-,258	-3,410	,001	-,111	-,030	,771	1,297
INF	-,173	,368	-,034	-,469	,639	-,898	,553	,845	1,184
IIP	-,082	,142	-,039	-,576	,565	-,363	,199	,974	1,027
VIX	,011	,010	,084	1,153	,250	-,008	,030	,833	1,200
CCI	,406	,606	,047	,670	,504	-,789	1,601	,914	1,094
INT	,020	,013	,113	1,595	,113	-,005	,046	,881	1,135
USD/GBP t-1	,183	,069	,183	2,664	,008	,048	,319	,935	1,069

a. Dependent Variable: USD/GBP

Slika 17: Faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL)-valutni par USD/GBP

Izvor: Izrada autorice

Na temelju vrijednosti prikazanih na slici 16, može se prihvatiti pretpostavka o ne postojanju multikolinearnosti, jer su za sve parametre regresije faktori inflacije varijance manji od 5, a postotak tolerancije je veći od 20%.

Nakon što su se provjerile sve navedene pretpostavke modela višestruke regresije i nakon zaključka da iste ispunjavanju postavljene kriterije može se ići na analizu konačnog regresijskog modela - Model 2b.

Kako i kod prethodnog valutnog para, model kao cjelina nije predmet ovoga istraživanja, već utjecaj pojedinih varijabli, no objasniti će se temeljni pokazatelji ovog modela. Koeficijent determinacije iznosi 0,195, odnosno 19,5%, što upućuje na lošu reprezentativnost modela kao cjeline. F - test iznosi 6,283 te je pri razini signifikantnosti od 1% Model 2b statistički značajan.

Što se tiče utjecaja pojedinih nezavisnih varijabli na zavisnu varijablu, kao značajne pokazale su se promjena cijene nafte (OIL), razlika u promjenama između kamatnih (INT) i promjena zavisne varijable s pomakom (USD/GBP t-1). Varijable INT i OIL značajne su pri signifikantnosti od 1%, dok je INT značajna pri 10%. (Tablicu 7). Utjecaj statističkih značajnih varijabli (OIL, INT i USD/GBP t-1) procijenjenog regresijskog modela jednaki su očekivanim utjecajima iz početno postavljenih hipoteza.

Utjecaj promijene cijene nafte (OIL) ima statistički značajan negativan utjecaj ($\hat{\beta}_7 = -0,070$) na promjenu tečaja USD/GBP, što znači kada cijena nafte poraste tečaj pada, odnosno američki dolar u odnosu na britansku funtu slabi, tj. deprecira. Na slici 13 vidi se da je američko gospodarstvo u većem dijelu promatranog razdoblja od 2000. do 2017. godine bilo više ovisno o uvozu nafte nego što je to bilo britansko gospodarstvo, iz toga slijedi i obrnuto proporcionalan odnosu cijene nafte i tečaja valutnog para USD/GBP. Dakle, prilikom rasta cijene nafte, rastu i cijene inputa za industriju, proizvodnju itd., američko gospodarstvo više je ovisno o samom uvozu nafte pa samim time snosi i više troškove zbog porasta cijene nafte. Zbog navedenog dolazi do porasta cijena američke robe u odnosu na britansku robu, te britanska funta zbog pada kupovne moći u SAD-u aprecira u odnosu na dolar.

Razlike u promjenama kamatnih stopa između SAD-a i Velike Britanije očekivano imaju pozitivan utjecaj ($\hat{\beta}_6 = 0,020$) na vrijednost američkog dolara (aprecijacija dolara). Dakle, ukoliko dođe do situacije da kamatne stope (dugoročne) u SAD-u porastu, dok one u Velikoj Britaniji ostanu nepromijenjene ili relativno narastu manje, očekuje se da će investitori svoja sredstva usmjeravati na investicije u američki dolar. Dakle, potražnja za američkim dolarom porast će dok će se istovremeno povećati ponuda funte, u konačnici navedeno vodi aprecijaciji dolara u odnosu na funtu.⁶⁹

Zavisna varijabla s pomakom, očekivano ima pozitivan utjecaj ($\hat{\beta}_7 = 0,183$) na kretanje promjene tečaja USD/GBP. Dakle ako je npr. tečaju prethodnom razdoblju rastao, očekuje se da će u sljedećem razdoblju on također rasti i obrnuto.

4.4. Utjecaj determinanti na kretanje tečaja USD/JPY

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 \cdot X_1 + \hat{\beta}_2 \cdot X_2 + \hat{\beta}_3 \cdot X_3 + \hat{\beta}_4 \cdot X_4 + \hat{\beta}_5 \cdot X_5 + \hat{\beta}_6 \cdot X_6 + e \quad (13)$$

\hat{Y} - postotna promjena vrijednosti dolara

X_1 - postotna promjena vrijednosti cijene nafte

X_2 - razlika između postotnih promjena američke i japanske razine inflacije

X_3 - razlika između postotnih promjena američke i japanske razine dohotka

X_4 - postotna promjena indeks rizičnosti

X_5 - razlika između postotnih promjena američkog i japanskog indeksa povjerenja potrošača

X_6 - razlika između postotnih promjena američke i japanske razine kamatnih stopa

$\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_6$ - parametri koji se procijenjuju

⁶⁹ Napomena: U SPSS-u je takoer ispitan utjecaj razlike u promjenama dugoročnih kamatnih stopa na kretanje promjene tečaja i također se pokazao statistički značajan.

e -slučajna greška

U tablici 9 prikazane su odabrane nezavisne varijable, njihove oznake u modelu te su prezentirani očekivani utjecaji pojedine varijable utjecaja na kretanje zavisne varijable - tečaja. Razlog pozitivnog/negativnog utjecaja pojedine nezavisne varijable prezentiran je već u dijelu hipoteza ovog rada.

Tablica 9: Prikaz očekivanog utjecaja varijabli na zavisnu varijablu - postotna promjena vrijednosti dolara (valutni par USD/JPY)

Varijable utjecaja	Indikator	Oznaka	Očekivani utjecaj
Postotna promjena vrijednosti cijene nafte	WTI	OIL	+
Razlika između postotnih promjena američke i japanske razine inflacije	(Harmonizirani) indeks potrošačkih cijena	INF	-
Razlika između postotnih promjena američke i japanske razine dohotka	Indeks industrijske proizvodnje	IIP	+/-
Postotna promjena indeks rizičnosti	VIX mjera volatilnosti S&P 500 indeksa	VIX	+
Razlika između postotnih promjena američkog i japanskog indeksa povjerenja potrošača	Indeks povjerenja potrošača	CCI	+
Razlika između postotnih promjena američke i japanske razine kamatnih stopa	Kratkoročna kamatna stopa na <i>treasury bills</i>	INT	+

Izvor: Izrada autorice

Kroz program SPSS ubačene su pojedine vrijednosti nezavisnih varijabli te je proveden postupak višestruke linearne regresije, s napomenom da kako bi mogli donijeti zaključke na temelju modela višestruke regresije potrebno je da model ispuni prethodno navedene četiri pretpostavke.

Ocijenjeni regresijski model - Model 3a nije zadovoljavao pretpostavku o ne postojanju autokorelacije. DW test veličina ovog modela iznosi 1,481. Prema tablicama kritičnih vrijednosti (Prilog 1), problem autokorelacije ne postoji, za $n=187$ i $k=6$, kada je DW test veličina $> (d_u)$, odnosno 1,82. Kako bi se riješio problem autokorelacije, uvodi se zavisna varijabla s pomakom (t-1), kao sedma nezavisna varijabla. Dakle, Model 3b sadrži sedam nezavisnih varijabli u razdoblju od svibnja 2002. godine do prosinca 2017. godine⁷⁰, ukupno

⁷⁰ Valutni par USD/JPY, analizira se tek od travnja, odnosno svibnja 2002. godine, jer podaci za pojedine varijable nisu dostupni za prva tri mjeseca 2002. godine.

187 opažanja. Uvođenjem zavisne varijable s pomakom problem autokorelacije više ne postoji, DW test veličina u Modelu 3b iznosi 2,049 što je veće od kritične vrijednosti iz DW tablica za $n=186$ i $k=7$. Dakle, $1,982 > (d_u)$, odnosno 1,84.

Tablica 10: Rezultati provedene regresijske analize za valutni par USD/JPY

Varijabla	Model 3a	Model 3b
Constant	0,000 (0,002)	2,709E-5 (0,002)
OIL	0,023 (0,022)	0,026 (0,021)
INF	0,072 (0,445)	-0,036 (0,431)
IIP	0,027 (0,075)	0,061 (0,074)
VIX	-0,042*** (0,010)	-0,045*** (0,009)
CCI	0,682 (0,679)	0,264 (0,666)
INT	0,029** (0,010)	0,025** (0,010)
USD/JPY t-1	- (0,070)	0,243*** (0,070)
F test	4,766***	6,234***
Koeficijent determinacije	0,137	0,197
Standardna pogreška	0,0224	0,0216
DW	1,481	2,049

Izvor: Izrada autorice

Napomena: ***, ** i * označavaju signifikantnost na razini 1%, 5% i 10% značajnosti, standardne pogreške parametara su dane u zagradama.

Tablica 11: Enter metoda - Model 3b - valutni par USD/JPY

VariablesEntered/Removed ^a			
Model	VariablesEntered	VariablesRemoved	Method
1	USD/JPY t-1, INF, VIX, IIP, INT, CCI, OIL ^b	.	Enter

a. DependentVariable: USD/JPY

b. Allrequestedvariablesentered.

Izvor: Izrada autorice

Tablica 11 daje prikaz konačnog regresijskog modela za USD/JPY koji se sastoji od 7 regresorskih varijabli, koje su u model ušle odjednom - ENTER metoda. Dakle, u odnosu na jednadžbu (13) u ovoj regresiji dodana je još nezavisna varijabla X_7 s pripadajućim parametrom - $\hat{\beta}_7$.

Prethodno je potvrđeno da autokorelacija ne postoji, no potrebno je ispitati i preostale tri pretpostavke.

Pomoću Spearmanovog koeficijenta korelacije ranga između apsolutnih vrijednosti reziduala i izabranih regresorskih varijabli ispitat će se problem heteroskedastičnosti varijance reziduala. Kod ovog testa najprije se postavljaju hipoteze koje su prethodno pojašnjene prilikom regresijske analize valutnog para USD/EUR, navedene vrijede i u ovom slučaju.

Slika 17 prikazuje izračunate Spearmanove koeficijente korelacije ranga, prikazana je i empirijska signifikantnost koeficijenata korelacije, čije su vrijednosti:

$\alpha^*_1 = 0,866$, $\alpha^*_2 = 0,972$, $\alpha^*_3 = 0,094$, $\alpha^*_4 = 0,990$, $\alpha^*_5 = 0,663$, $\alpha^*_6 = 0,809$ i $\alpha^*_7 = 0,039$.

Correlations			OIL	INF	IIP	VIX	CCI	INT	USD/JPY t-1	absres
Spearman's rho	OIL	Correlation Coefficient	1,000	,349**	-,053	-,095	-,144*	-,175*	-,095	,012
		Sig. (2-tailed)	.	,000	,474	,197	,049	,017	,196	,866
		N	186	186	186	186	186	186	186	186
	INF	Correlation Coefficient	,349**	1,000	-,003	,078	-,185*	-,118	-,072	-,003
		Sig. (2-tailed)	,000	.	,969	,289	,012	,110	,328	,972
		N	186	186	186	186	186	186	186	186
	IIP	Correlation Coefficient	-,053	-,003	1,000	,040	,019	,075	-,110	-,123
		Sig. (2-tailed)	,474	,969	.	,589	,797	,310	,133	,094
		N	186	186	186	186	186	186	186	186
	VIX	Correlation Coefficient	-,095	,078	,040	1,000	-,132	,173*	,127	,001
		Sig. (2-tailed)	,197	,289	,589	.	,073	,018	,084	,990
		N	186	186	186	186	186	186	186	186
	CCI	Correlation Coefficient	-,144*	-,185*	,019	-,132	1,000	-,080	,168*	,032
		Sig. (2-tailed)	,049	,012	,797	,073	.	,280	,022	,663
		N	186	186	186	186	186	186	186	186
	INT	Correlation Coefficient	-,175*	-,118	,075	,173*	-,080	1,000	,086	,018
		Sig. (2-tailed)	,017	,110	,310	,018	,280	.	,243	,809
		N	186	186	186	186	186	186	186	186
	USD/JPY t-1	Correlation Coefficient	-,095	-,072	-,110	,127	,168*	,086	1,000	,151*
		Sig. (2-tailed)	,196	,328	,133	,084	,022	,243	.	,039
		N	186	186	186	186	186	186	186	186
	absres	Correlation Coefficient	,012	-,003	-,123	,001	,032	,018	,151*	1,000
		Sig. (2-tailed)	,866	,972	,094	,990	,663	,809	,039	.
		N	186	186	186	186	186	186	186	186

**, Correlation is significant at the 0.01 level (2-tailed).

*, Correlation is significant at the 0.05 level (2-tailed).

Slika 18: Slika14: Spearmanovi koeficijenti korelacije - valutni par USD/JPY

Izvor: Izrada autorice


Vrijednosti (α^*) u šest od sedam slučajeva veća je od 5%, samo je kod varijable USD/JPY t-1 ona manja od 5%, no kako $\alpha^*_7 = 0,039$ ne odstupa puno od 5% prihvaća se nulta hipoteza da

korelacija nije statistički značajna. Dakle, može se zaključiti da u modelu ne postoji problem heteroskedastičnosti varijance reziduala.

Kako bi se provjerila pretpostavka normalnosti reziduala, koristit će se histogram standardiziranih reziduala i P-P grafikom normalno distribuiranih reziduala.


Grafikon 7 prikazuje histogram standardiziranih reziduala, gdje se može vidjeti da su reziduali normalno distribuirani, s očekivanjem približno jednakim nuli i standardnom devijacijom približno jednakoj jedinici.

Grafikon 7: Histogram standardiziranih reziduala - valutni par USD/JPY



Izvor: Izrada autorice

Grafikon 8: P-P grafikon normalno distribuiranih reziduala- valutni par USD/JPY



Izvor: Izrada autorice

Na kraju, potrebno je još ispitati postojanje multikolinearnosti nezavisnih varijabli pomoću faktora inflacije varijance (VIF_j), i njegove recipročne vrijednosti (TOL_j), navedene su prezentirane na slici 18:

Slika 19: Faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL)- valutni par USD/JPY

Coefficients ^a									
Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
	B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
1 (Constant)	2,709E-5	,002		,016	,987	-,003	,003		
OIL	,026	,021	,096	1,245	,215	-,015	,068	,763	1,311
INF	-,036	,431	-,006	-,085	,933	-,886	,813	,809	1,236
IIP	,061	,074	,056	,815	,416	-,086	,207	,941	1,063
VIX	-,045	,009	-,342	-4,743	,000	-,064	-,026	,867	1,154
CCI	,264	,666	,028	,396	,693	-1,051	1,579	,891	1,123
INT	,025	,010	,179	2,555	,011	,006	,045	,917	1,091
USD/JPY t-1	,243	,070	,245	3,483	,001	,105	,381	,914	1,094

a. Dependent Variable: USD/JPY

Izvor: Izrada autorice

Na temelju vrijednosti prikazanih na slici 18, može se prihvatiti pretpostavka o ne postojanju multikolinearnosti, jer su za sve parametre regresije faktori inflacije varijance manji od 5, a postotak tolerancije je veći od 20%.

Sve navedene pretpostavke modela višestruke regresije su ispunjene te se može se ići na analizu konačnog regresijskog modela - Model 3b.

Kako i kod prethodnog valutnog para, model kao cjelina nije predmet ovoga istraživanja, već utjecaj pojedinih varijabli, no objasniti će se temeljni pokazatelji ovog modela. Koeficijent determinacije iznosi 0,197, odnosno 19,7%, što upućuje na lošu reprezentativnost modela kao cjeline. F - test iznosi 6,283 te je pri razini signifikantnosti od 1% Model 3b statistički značajan.

Kao značajne varijable utjecaja, pokazale su se promjena VIX indeksa (VIX), razlika u promjenama između kamatnih (INT) i promjena zavisne varijable s pomakom (USD/GBP t-1). Varijable VIX i USD/JPY t-1 značajne su pri signifikantnosti od 1%, dok je INT značajna pri 5%. (Tablica 10).

Negativan utjecaj VIX indeksa suprotan je od očekivanog. Prethodno je objašnjeno da kada VIX bilježi visoke vrijednosti (kada averzija investitora raste), očekuje se aprecijacija američkog dolara u odnosu na odabranu valutu. Pozitivan utjecaj VIX indeksa na tečaj USD/JPY objašnjen je činjenicom što se japanski jen u svijetu percipira kao sigurna valuta (engl. *safetycurrency*). Općenito sigurnom valutom smatra se ona valuta čija država ima niske kamatne stope, visoko likvidno financijsko tržište i NFA (Net foreign assets).

Slijede neki od razloga percepcije jena kao sigurne valute:⁷¹

- Japan je oduvijek značajno više proizvoda izvezio nego uvezio, jedan je od najvećih neto izvoznika u svijetu, dakle bilježi vanjskotrgovinski suficit.
- Vrijednost inozemne imovine u vlasništvu japanskih investitora značajno je veća od vrijednosti japanske imovine „u rukama“ stranaca.
- Japanski jen je tzv. *carrytrade* valuta, *carrytrade* strategija predstavlja zaduživanje u valuti koja ima niske kamatne stope i plasiranje sredstava u valute s visokim kamatnim stopama.

Dakle, činjenica je da u uvjetima nesigurnosti i visoke averzije investitora prema riziku japanski jen aprecira.

⁷¹ FINANCIAL SENCE (2016.): Why Is the Japanese Yen a Safe-Haven Currency?, [Internet], raspoloživo na : <https://www.financialsense.com/contributors/matthew-kerkhoff/why-japanese-yen-safe-haven-currency>, [03.08.2018.]

Razlike u promjenama kamatnih stopa između SAD-a i Japana očekivano imaju pozitivan utjecaj ($\hat{\beta}_6 = 0,025$) na vrijednost američkog dolara (aprecijacija dolara). Dakle, ukoliko dođe do situacije da kamatne stope (kratkoročne) u SAD-u porastu, dok one u Japanu ostanu nepromijenjene ili pak relativno narastu manje, očekuje se da će investitori svoja sredstva usmjeravati na investicije u američki dolar. Dakle, potražnja za američkim dolarom porast će dok će se istovremeno povećati ponuda jena, u konačnici navedeno vodi aprecijaciji dolara u odnosu na japanski jen.⁷²

Zavisna varijabla s pomakom, očekivano ima pozitivan utjecaj ($\hat{\beta}_7 = 0,243$) na kretanje promjene tečaja USD/JPY, dakle ako je tečaj u prethodnom razdoblju rastao, očekuje se da će u sljedećem razdoblju on također rasti i obrnuto.

⁷² Napomena: U SPSS-u je također ispitan utjecaj razlike u promjenama dugoročnih kamatnih stopa na kretanje promjene tečaja, no nije se pokazao statistički značajan.

5. ZAKLJUČAK

Cilj ovog istraživanja s empirijskog stajališta, bio je ispitati utjecaj određenih varijabli na kretanje jedne od najznačajnijih varijabli svakog gospodarstva - deviznog tečaja. Važnost deviznog tečaja može se promatrati s više razina, od pojedinca (npr. zaduživanje s valutnom klauzulom) preko multinacionalne kompanije (remitiranje sredstava ovisnom društvu, odluke o financiranju, investiranju, itd.) do cjelokupnog gospodarstva (npr. konkurentnost izvoznih proizvoda države). Valutni parovi (USD/EUR, USD/GBP i USD/JPY) izabrani su zbog važnosti u dnevnom prometu i trgovini na FX tržištu (ukupno čine oko 50% prometa).

Zbog nepredvidljivosti deviznog tečaja i mijenjanja istog iz sekunde u sekundu vrlo je teško, gotovo nemoguće predvidjeti razinu deviznog tečaja u bilo kojem vremenskom periodu. Ipak postoje određene teorijski definirane varijable za koje se smatra da sigurno imaju utjecaj na kretanje tečaja određene valute, a to su: kretanje kamatnih stopa, inflacije i dohotka države. U ovom radu osim navedenih provedena je i analiza utjecaja tri novo uvedene varijable: cijena nafte, indeks potrošačkog povjerenja i VIX „indeks straha“. Osim šest prethodno navedenih varijabli koje se mogu kvantificirati, na kretanje deviznog tečaja značajno utječu vijesti iz cijelog svijeta, špekulacije i očekivanja, odnosno varijable čiji utjecaj se ne može brojčano odrediti.

U ovom radu, metodom višestruke regresije ispitan je utjecaj šest nezavisnih varijabli na kretanje tečaja tri valutna para. Potrebno je napomenuti da su vrijednosti koeficijenata determinacije za sve modele vrlo niski. Regresijskom analizom utvrđeno je da kamatne stope⁷³ statistički značajno i pozitivno utječu na kretanje sva tri valutna para, također VIX indeks strana pokazao sta statistički značajan u dva valutna para; USD/EUR i USD/JPY. U valutnom paru USD/EUR ima statistički značajan pozitivan utjecaj, kako je hipotezom i pretpostavljeno, dok u valutnom paru USD/JPY postoji statistički značajan i negativan utjecaj zbog percepcije japanskog jena kao sigurne valute. Varijable razina dohotka, indeks potrošačkog povjerenja i cijena nafte nisu se pokazale statistički pozitivno značajne ni u jednom modelu. Stoga hipoteza **H1 o statistički značajnom pozitivnom utjecaju kamatne stope, razina dohotka, indeks potrošačkog optimizma, percepcija rizika investitora i cijena nafte na kretanje tečaja američkog dolara** može biti djelomično prihvaćena.

Negativan utjecaj razine inflacije i dohotka nije se pokazao statistički značajan za nijedan valutni par. Varijabla cijena nafte pokazala se statistički negativno značajna u dva od

⁷³ Napomena: Za valutni par USD/EUR značajne su se pokazale samo dugoročne kamatne stope.

tri valutna para, USD/EUR i USD/JPY. Dakle, hipoteza **H2 o statistički značajnom negativnom utjecaju stopa inflacije, razina dohotka i cijena nafte na kretanje tečaja američkog dolara** može biti djelomično prihvaćena.

Doprinos ovog istraživanja ogleda se u činjenici da su se analizirala kretanja tečajeva najvažnijih svjetskih valuta za koje se može reći da imaju ulogu svjetskog novca. Također, istražio utjecaj temeljnih teorijskih determinanti (kamatna stopa, inflacija te dohotka kroz IIP) zajedno s novim neistraženim varijablama (CCI i VIX indeks).

Model višestruke regresije koji je korišten u ovom radu ima određena ograničenja i nedostatke. Prvenstveno koeficijenti parametara regresije za razdoblje od 2002. do 2017. godine ne moraju vrijediti za neka druga vremenska razdoblja, jer se utjecajem određenih faktora oni mijenjaju. Nadalje, postoje već prethodno spomenuti faktori koji se ne mogu kvantificirati (npr. očekivanja, špekulacije, devizne kontrole), a FX tržište je na njih osjetljivo jer kao i svako drugo financijsko tržište brzo reagira na vijesti. Također, problem mogu izazvati odgođeni utjecaji određenih varijabli koji su nepoznati, a sve varijable ne moraju reagirati na devizni tečaj u istom periodu promatranja. Navedena ograničenja predstavljaju smjernice za daljnja poboljšana istraživanja utjecaja determinanti na kretanje tečaja. Nadalje, bilo bi korisno istražiti utjecaj navedenih determinanti na kretanje primjerice DXY (U.S. dollar Index, Spot Rate). Tada dolar nije promatran u odnosu na svaku valutu zasebno, već se promatra kretanje američkog dolara u odnosu na košaricu valuta.

LITERATURA:

Knjige:

1. Gandolfo, G. (2002.): International Finance and Open-Economy Macro-economics, Science and Business Media, Springer
2. Lovrinović, I. (2015): Globalne financije, ACCENT, Zagreb
3. Madura, J. (2008): International Financial Management, Thomson Higher Education, 9th edition
4. Pilbeam K., (2006): International Finance, Palgrave Macmillan, New York, 3rd edition
5. Zelenika, R. (2000): Metodologija i tehnologija izrade znanstvenog i stručnog djela, Ekonomski fakultet Rijeka

Internet izvori:

1. Bank for International Settlements: Statistics, Foreign exchange trading, [Internet], raspoloživo na: https://www.bis.org/statistics/dl1_1.pdf, [20.07.2018.]
2. Bank for International Settlements (2016): Triennial Central Bank Survey, Foreign exchange turnover in April 2016, [Internet], raspoloživo na: <https://www.bis.org/publ/rpfx16fx.pdf>, [20.07.2018.]
3. Büyüksahin, Bahattin, and Jeffrey H. Harris. 2011. Do Speculators Drive Crude Oil Futures? Energy Journal 32
4. Cifarelli, Giulio, and Giovanna Paladino. 2010. Oil price dynamics and speculation: A multivariate financial approach. Energy Economics 32
5. Clostermann J., Schnatz B., (2000): The determinants of euro-dollar exchange rate- Synthetic fundamentals and non-existing currency, Deutsche Bundesbank, Frankfurt am Main
6. Erten, Bilge, and Jose Antonio Ocampo. 2012. Super-cycles of commodity prices since the mid-nineteenth century. DESA Working Paper, No. 110. New York, NY, USA: United Nations Department of Economic and Social Affairs
7. EuroFX: Sudionici na deviznom tržištu, [Internet], raspoloživo na : <http://www.eurofx.ru/hr/uchastniki-valyutnogo-rynka-foreks/>, [11.07.2018.]
8. Fattouh, Bassam, and Pasquale Scaramozzino. 2011. Uncertainty, Expectations, and Fundamentals: Whatever Happened to Long-Term Oil Prices? Oxford Review of Economic Policy 27

9. FINANCIAL SENCE (2016.): Why Is the Japanese Yen a Safe-Haven Currency?, [Internet], raspoloživo na : <https://www.financialsense.com/contributors/matthew-kerkhoff/why-japanese-yen-safe-haven-currency> , [03.08.2018.]
10. Fortrade: Edukacija – devizni tečaj, [Internet], raspoloživo na : <https://www.fortrade.eu/edukacija/clanci/valutni-derivati/devizni-tecaj/> , [10.07.2018.]
11. FRED Economic Data: CBOE Volatility Index, raspoloživo na: <https://fred.stlouisfed.org/series/VIXCLS>, [28.04.2018.]
12. FRED: Economic Data, [Internet], raspoloživo na : <https://fred.stlouisfed.org>, [23.07.2018.]
13. HNB: Rizici za potrošača u kreditnom odnosu, , raspoloživo na : <https://www.hnb.hr/-/rizici-za-potrosaca-u-kreditnom-odnosu>, [25.04.2018.]
14. International Monetary Fund: Data by Indicator [Internet], raspoloživo na : <http://data.imf.org/?sk=388DFA60-1D26-4ADE-B505-A05A558D9A42> , [23.07.2018.]
15. International Monetary Fund: International Financial Statistics raspoloživo na: <http://www.imf.org/external/index.htm>, [28.04.2018.]
16. Liao, J., Shi, Y., Xu, X.: Why Is the Correlation between Crude Oil Prices and the US Dollar Exchange Rate Time-Varying?— Explanations Based on the Role of Key Mediators, International Journal of Financial Studies, June 2018
17. Macrotrends: Crude Oil Prices - 70 Year Historical Chart, raspoloživo na : <http://www.macrotrends.net/1369/crude-oil-price-history-chart>, [28.04.2018.]
18. OECD: Leading indicators, raspoloživo na: <https://data.oecd.org/leadind/business-confidence-index-CCI.htm>, [28.04.2018.]
19. OECD: OECD Data, [Internet], raspoloživo na : <https://stats.oecd.org/index.aspx?queryid=350#> , [23.07.2018.]
20. OTP invest: Devizni tečaj, raspoloživo na: <http://www.otpinvest.hr/main.aspx?id=102>, [23.04.2018.]
21. Poslovni dnevnik: Leksikon-hedging, raspoloživo na : <http://www.poslovni.hr/leksikon/hedging-226>, [27.04.2018.]
22. Ramasamy R., Abar S.K., (2015): Influence of Macroeconomic Variables on Exchange Rates, Journal of Economics, Business and Management, Vol. 3, No. 2
23. Studentski.hr: Materials, [Internet], raspoloživo na : <http://studentski.hr/system/materials/o/961b690552175852c10c7c133a35935dd34e97c4.zip?1439380096>, [10.07.2018.]

24. Tan, A.S. (2013): A Regression Analysis on the Factors that Affect Exchange Rate in Developing Countries, The School of Economics De la Salle University – Manila
25. Tečajna lista: Mijenjanje i predviđanje tečaja, raspoloživo na : <http://www.tecajnalista.info/mijenjanje-i-predvidanje-tecaja.htm>, [23.04.2018.]
26. Tomić Z., (2014): Utjecaj makroekonomskih varijabli na spot devizno tržište, Diplomski rad, Ekonomski fakultet Zagreb
27. Trading Economics: United States, Indicators, raspoloživo na: <https://tradingeconomics.com/united-states/indicators> , [29.07.2018.]
28. Urrutia J. D., Olfindo M. L. T., Tampis R., (2015): Modelling and forecasting the exchange rate of the Philippines: a time series analysis, AMERICAN RESEARCH THOUGHTS- Volume 1, Issue 9
29. Wikipedia: Euro, raspoloživo na : <https://hr.wikipedia.org/wiki/Euro>, [23.04.2018.]
30. World Bank: Energy imports, net (% of energy use), [Internet], raspoloživo na: <https://data.worldbank.org/indicator/EG.IMP.CON.S.ZS?contextual=default&end=2015&locations=JP-US-GB-XC&start=2000&view=chart>, [20.07.2018.]

Nastavni materijali:

1. Jurun, E. (2007.): Nastavni materijali kolegija „Kvantitativne metode u ekonomiji“, Ekonomski fakultet Split
2. Pivac, S. (2010.): E -nastavni materijali kolegija „Statističke metode“, Ekonomski fakultet Split

POPIS GRAFIKONA, SLIKA I TABLICA

Popis grafikona:

Grafikon 1: OTC FX promet po valutnim parovima.....	35
Grafikon 2: Histogram standardiziranih reziduala - valutni par USD/EUR	45
Grafikon 3: P-P grafikon normalno distribuiranih reziduala - valutni par USD/EUR.....	46
Grafikon 4: Kretanje tečaja USD/EUR i cijene nafte - WTI u razdoblju od siječnja 2002. do prosinca 2017. godine	49
Grafikon 5: Histogram standardiziranih reziduala - valutni par USD/GBP.....	55
Grafikon 6: P-P grafikon normalno distribuiranih reziduala- valutni par USD/GBP	55
Grafikon 7: Histogram standardiziranih reziduala - valutni par USD/JPY.....	62
Grafikon 8: P-P grafikon normalno distribuiranih reziduala- valutni par USD/JPY	62

Popis slika:

Slika 1: Potražnja za funtom	13
Slika 2: Ponuda za funtom	14
Slika 3: Fiksni devizni režim.....	16
Slika 4: Fluktuirajući devizni režim	17
Slika 5: Inozemni novčani tokovi multinacionalne kompanije	19
Slika 6: Određivanje ravnotežnog deviznog tečaja	20
Slika 7: Utjecaj porasta inflacije u SAD-u na ravnotežni tečaj britanske funte	21
Slika 8: Utjecaj porasta kamatnjaka u SAD-u na ravnotežni tečaj britanske funte.....	22
Slika 9: Utjecaj porasta kamatnjaka u SAD-u na ravnotežni tečaj britanske funte.....	24
Slika 10: Utjecaj čimbenika na devizni tečaj prema trgovinskim/financijskim odnosima	25
Slika 11: OTC promet FX instrumenata, travanj 2016	34
Slika 12: Distribucija valuta prema OTC FX prometu na neto-neto bazi	35
Slika 13: Uvoz energije, neto (% od potrošnje energije)	38
Slika 14: Spearmanovi koeficijenti korelacije - valutni par USD/EUR.....	44

Slika 15: Faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL) - valutni par USD/EUR.....	46
Slika 16: Spearmanovi koeficijenti korelacije - valutni par USD/GBP	54
Slika 17: Faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL) - valutni par USD/GBP	56
Slika 18: Slika14: Spearmanovi koeficijenti korelacije - valutni par USD/JPY	61
Slika 19: Faktor inflacije varijance (VIF) i ekvivalentni pokazatelj tolerancije (TOL) - valutni par USD/JPY	63

Popis tablica:

Tablica 1: Prikaz međunarodnog Fisherovog efekta iz perspektive različitih investitora	30
Tablica 2: Prikaz očekivanog utjecaja varijabli na zavisnu varijablu - postotna promjena vrijednosti dolara (valutni par USD/EUR).....	42
Tablica 3: Rezultati provedene regresijske analize za valutni par USD/EUR	43
Tablica 4: Enter metoda - Model 1b - valutni par USD/EUR.....	43
Tablica 5: Rezultati provedene regresijske analize za valutni par USD/EUR (umjesto kratkoročnih k.s. korištene su dugoročne k.s.).....	50
Tablica 6: Prikaz očekivanog utjecaja varijabli na zavisnu varijablu - postotna promjena vrijednosti dolara (valutni par USD/GBP).....	52
Tablica 7: Rezultati provedene regresijske analize za valutni par USD/GBP	53
Tablica 8: Enter metoda - Model 2b - valutni par USD/GBP	53
Tablica 9: Prikaz očekivanog utjecaja varijabli na zavisnu varijablu - postotna promjena vrijednosti dolara (valutni par USD/JPY)	58
Tablica 10: Rezultati provedene regresijske analize za valutni par USD/JPY.....	59
Tablica 11: Enter metoda - Model 3b - valutni par USD/JPY	59

PRILOZI:

Prilog 1: Kritične vrijednosti DW testa

Critical Values for the Durbin-Watson Statistic (d)										
Level of Significance $\alpha = .05$										
<i>n</i>	<i>k</i> = 1		<i>k</i> = 2		<i>k</i> = 3		<i>k</i> = 4		<i>k</i> = 5	
	<i>d</i> _L	<i>d</i> _U	<i>d</i> _L	<i>d</i> _U	<i>d</i> _L	<i>d</i> _U	<i>d</i> _L	<i>d</i> _U	<i>d</i> _L	<i>d</i> _U
6	0.61	1.40								
7	0.70	1.36	0.47	1.90						
8	0.76	1.33	0.56	1.78	0.37	2.29				
9	0.82	1.32	0.63	1.70	0.46	2.13	0.30	2.59		
10	0.88	1.32	0.70	1.64	0.53	2.02	0.38	2.41	0.24	2.82
11	0.93	1.32	0.66	1.60	0.60	1.93	0.44	2.28	0.32	2.65
12	0.97	1.33	0.81	1.58	0.66	1.86	0.51	2.18	0.38	2.51
13	1.01	1.34	0.86	1.56	0.72	1.82	0.57	2.09	0.45	2.39
14	1.05	1.35	0.91	1.55	0.77	1.78	0.63	2.03	0.51	2.30
15	1.08	1.36	0.95	1.54	0.82	1.75	0.69	1.97	0.56	2.21
16	1.10	1.37	0.98	1.54	0.86	1.73	0.74	1.93	0.62	2.15
17	1.13	1.38	1.02	1.54	0.90	1.71	0.78	1.90	0.67	2.10
18	1.16	1.39	1.05	1.53	0.93	1.69	0.92	1.87	0.71	2.06
19	1.18	1.4	1.08	1.53	0.97	1.68	0.86	1.85	0.75	2.02
20	1.20	1.41	1.10	1.54	1.00	1.68	0.90	1.83	0.79	1.99
21	1.22	1.42	1.13	1.54	1.03	1.67	0.93	1.81	0.83	1.96
22	1.24	1.43	1.15	1.54	1.05	1.66	0.96	1.80	0.96	1.94
23	1.26	1.44	1.17	1.54	1.08	1.66	0.99	1.79	0.90	1.92
24	1.27	1.45	1.19	1.55	1.10	1.66	1.01	1.78	0.93	1.90
25	1.29	1.45	1.21	1.55	1.12	1.66	1.04	1.77	0.95	1.89
26	1.30	1.46	1.22	1.55	1.14	1.65	1.06	1.76	0.98	1.88
27	1.32	1.47	1.24	1.56	1.16	1.65	1.08	1.76	1.01	1.86
28	1.33	1.48	1.26	1.56	1.18	1.65	1.10	1.75	1.03	1.85
29	1.34	1.48	1.27	1.56	1.20	1.65	1.12	1.74	1.05	1.84
30	1.35	1.49	1.28	1.57	1.21	1.65	1.14	1.74	1.07	1.83

31	1.36	1.50	1.30	1.57	1.23	1.65	1.16	1.74	1.09	1.83
32	1.37	1.50	1.31	1.57	1.24	1.65	1.18	1.73	1.11	1.82
33	1.38	1.51	1.32	1.58	1.26	1.65	1.19	1.73	1.13	1.81
34	1.39	1.51	1.33	1.58	1.27	1.65	1.21	1.73	1.15	1.81
35	1.40	1.52	1.34	1.58	1.28	1.65	1.22	1.73	1.16	1.80
36	1.41	1.52	1.35	1.59	1.29	1.65	1.24	1.73	1.18	1.80
37	1.42	1.53	1.36	1.59	1.31	1.66	1.25	1.72	1.19	1.80
38	1.43	1.54	1.37	1.59	1.32	1.66	1.26	1.72	1.21	1.79
39	1.43	1.54	1.38	1.60	1.33	1.66	1.27	1.72	1.22	1.79
40	1.44	1.54	1.39	1.60	1.34	1.66	1.29	1.72	1.23	1.79
45	1.48	1.57	1.43	1.62	1.38	1.67	1.34	1.72	1.29	1.78
50	1.50	1.59	1.46	1.63	1.42	1.67	1.38	1.72	1.34	1.77
55	1.53	1.60	1.49	1.64	1.45	1.68	1.41	1.72	1.38	1.77
60	1.55	1.62	1.51	1.65	1.48	1.69	1.44	1.73	1.41	1.77
65	1.57	1.63	1.54	1.66	1.50	1.70	1.47	1.73	1.44	1.77
70	1.58	1.64	1.55	1.67	1.52	1.70	1.49	1.74	1.46	1.77
75	1.60	1.65	1.57	1.68	1.54	1.71	1.51	1.74	1.49	1.77
80	1.61	1.66	1.59	1.69	1.56	1.72	1.53	1.74	1.51	1.77
85	1.62	1.67	1.60	1.70	1.57	1.72	1.55	1.75	1.52	1.77
90	1.63	1.68	1.61	1.70	1.59	1.73	1.57	1.75	1.54	1.78
95	1.64	1.69	1.62	1.71	1.60	1.73	1.58	1.75	1.56	1.78
100	1.65	1.69	1.63	1.72	1.61	1.74	1.59	1.76	1.57	1.78
150	1.72	1.75	1.71	1.76	1.69	1.77	1.68	1.79	1.66	1.80
200	1.76	1.78	1.75	1.79	1.74	1.80	1.73	1.81	1.72	1.82

Where n = number of observations and k = number of independent variables

Critical Values for the Durbin-Watson Statistic (d)										
Level of Significance $\alpha = .05$										
n	$k = 6$		$k = 7$		$k = 8$		$k = 9$		$k = 10$	
	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U	d_L	d_U

11	0.20	3.01								
12	0.27	2.83	0.17	3.15						
13	0.33	2.70	0.23	2.99	0.15	3.27				
14	0.39	2.57	0.29	2.85	0.20	3.11	0.13	3.36		
15	0.45	2.47	0.34	2.73	0.25	2.98	0.18	3.22	0.11	3.44
16	0.50	2.39	0.40	2.62	0.30	2.86	0.22	3.09	0.16	3.30
17	0.55	2.32	0.45	2.54	0.36	2.76	0.27	2.98	0.20	3.18
18	0.60	2.26	0.50	2.47	0.41	2.67	0.32	2.87	0.24	3.07
19	0.65	2.21	0.55	2.40	0.46	2.59	0.37	2.78	0.29	2.97
20	0.69	2.16	0.60	2.34	0.50	2.52	0.42	2.70	0.34	2.89
21	0.73	2.12	0.64	2.30	0.55	2.46	0.46	2.63	0.38	2.81
22	0.77	2.09	0.68	2.25	0.59	2.41	0.51	2.57	0.42	2.73
23	0.80	2.06	0.72	2.21	0.63	2.36	0.55	2.51	0.47	2.67
24	0.84	2.04	0.75	2.17	0.67	2.32	0.58	2.46	0.51	2.61
25	0.87	2.01	0.78	2.14	0.70	2.28	0.62	2.42	0.54	2.56
26	0.90	1.99	0.82	2.12	0.74	2.24	0.66	2.38	0.58	2.51
27	0.93	1.97	0.85	2.09	0.77	2.22	0.69	2.34	0.62	2.47
28	0.95	1.96	0.87	2.07	0.80	2.19	0.72	2.31	0.65	2.43
29	0.98	1.94	0.90	2.05	0.83	2.16	0.75	2.28	0.68	2.40
30	1.00	1.93	0.93	2.03	0.85	2.14	0.78	2.25	0.71	2.36
31	1.02	1.92	0.95	2.02	0.88	2.12	0.81	2.23	0.74	2.33
32	1.04	1.91	0.97	2.00	0.90	2.10	0.84	2.20	0.77	2.31
33	1.06	1.90	0.99	1.99	0.93	2.09	0.86	2.18	0.80	2.28
34	1.08	1.89	1.02	1.98	0.95	2.07	0.89	2.16	0.82	2.26
35	1.10	1.88	1.03	1.97	0.97	2.05	0.91	2.14	0.85	2.24
36	1.11	1.88	1.05	1.96	0.99	2.04	0.93	2.13	0.87	2.22
37	1.13	1.87	1.07	1.95	1.01	2.03	0.95	2.11	0.89	2.20
38	1.50	1.86	1.09	1.94	1.03	2.02	0.97	2.10	0.91	2.18
39	1.16	1.86	1.10	1.93	1.05	2.01	0.99	2.09	0.93	2.16
40	1.18	1.85	1.12	1.92	1.06	2.00	1.01	2.07	0.95	2.15

45	1.24	1.84	1.19	1.90	1.14	1.96	1.09	2.02	1.04	2.09
50	1.29	1.82	1.25	1.88	1.20	1.93	1.16	1.99	1.11	2.04
55	1.33	1.81	1.29	1.86	1.25	1.91	1.21	1.96	1.17	2.01
60	1.37	1.81	1.34	1.85	1.30	1.89	1.26	1.94	1.22	1.98
65	1.40	1.81	1.37	1.84	1.34	1.88	1.30	1.92	1.27	1.96
70	1.43	1.80	1.40	1.84	1.37	1.87	1.34	1.91	1.31	1.95
75	1.46	1.80	1.43	1.83	1.40	1.87	1.37	1.90	1.34	1.94
80	1.48	1.80	1.45	1.83	1.43	1.86	1.40	1.89	1.37	1.93
85	1.50	1.80	1.47	1.83	1.49	1.86	1.42	1.89	1.40	1.92
90	1.52	1.80	1.49	1.83	1.47	1.85	1.45	1.88	1.42	1.91
95	1.54	1.80	1.51	1.83	1.49	1.85	1.46	1.88	1.44	1.90
100	1.55	1.80	1.53	1.83	1.50	1.85	1.48	1.87	1.46	1.90
150	1.65	1.82	1.64	1.83	1.62	1.85	1.60	1.86	1.59	1.88
200	1.71	1.83	1.70	1.84	1.69	1.85	1.68	1.86	1.67	1.87

Where n = number of observations and k = number of independent variables

Prilog 2: Prikaz osnovnih podataka i dokaz o ispunjavanju pretpostavki Modela 1d

Variables Entered/Removed^a

Model	Variables Entered	Variables Removed	Method
1	USD/EUR t-1, INT, IIP, CCI, VIX, INF, OIL ^b	.	Enter



a. Dependent Variable: USD/EUR

Correlations

			OIL	INF	IIP	VIX	CCI	INT	USD/EUR t-1	absres
Spearman's rho	OIL	Correlation Coefficient	1,000	,173*	-,035	-,101	-,200**	,083	-,124	-,116
		Sig. (2-tailed)	.	,017	,636	,165	,006	,257	,088	,110
		N	190	190	190	190	190	190	190	190
	INF	Correlation Coefficient	,173*	1,000	-,161*	,089	-,293**	-,073	-,188**	-,124
		Sig. (2-tailed)	,017	.	,026	,224	,000	,314	,010	,087
		N	190	190	190	190	190	190	190	190
	IIP	Correlation Coefficient	-,035	-,161*	1,000	,040	,069	,018	,065	-,044
		Sig. (2-tailed)	,636	,026	.	,580	,344	,806	,373	,543
		N	190	190	190	190	190	190	190	190
	VIX	Correlation Coefficient	-,101	,089	,040	1,000	-,148*	-,274**	-,008	,017
		Sig. (2-tailed)	,165	,224	,580	.	,041	,000	,915	,818
		N	190	190	190	190	190	190	190	190
	CCI	Correlation Coefficient	-,200**	-,293**	,069	-,148*	1,000	,014	,212**	,159*
		Sig. (2-tailed)	,006	,000	,344	,041	.	,850	,003	,029
		N	190	190	190	190	190	190	190	190
	INT	Correlation Coefficient	,083	-,073	,018	-,274**	,014	1,000	,084	,014
		Sig. (2-tailed)	,257	,314	,806	,000	,850	.	,248	,852
		N	190	190	190	190	190	190	190	190
	USD/EUR t-1	Correlation Coefficient	-,124	-,188**	,065	-,008	,212**	,084	1,000	,053
		Sig. (2-tailed)	,088	,010	,373	,915	,003	,248	.	,467
		N	190	190	190	190	190	190	190	190
	absres	Correlation Coefficient	-,116	-,124	-,044	,017	,159*	,014	,053	1,000
		Sig. (2-tailed)	,110	,087	,543	,818	,029	,852	,467	.
		N	190	190	190	190	190	190	190	190

*. Correlation is significant at the 0.05 level (2-tailed).

**. Correlation is significant at the 0.01 level (2-tailed).



Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95,0% Confidence Interval for B		Collinearity Statistics	
	B	Std. Error	Beta			Lower Bound	Upper Bound	Tolerance	VIF
1 (Constant)	-,001	,002		-,549	,584	-,004	,002		
OIL	-,069	,019	-,251	-3,522	,001	-,107	-,030	,854	1,170
INF	,249	,349	,050	,714	,476	-,440	,939	,886	1,129
IIP	,087	,154	,038	,563	,574	-,217	,391	,944	1,060
VIX	,017	,009	,131	1,859	,065	-,001	,036	,875	1,143
CCI	1,070	,680	,110	1,574	,117	-,271	2,411	,890	1,124
INT	,053	,020	,182	2,677	,008	,014	,091	,937	1,067
USD/EUR t-1	,220	,069	,221	3,197	,002	,084	,356	,911	1,098

a. Dependent Variable: USD/EUR

Izvor : Izrada autorice

SAŽETAK

Devizni tečaj kao varijabla ekonomske politike sveprisutna je u cijelom gospodarstvu i ima višestruku važnost. Važnost deviznog tečaja može se promatrati pomoću više razina, od pojedinca (npr. zaduživanje s valutnom klauzulom) preko multinacionalne kompanije (remitiranje sredstava ovisnom društvu, odluke o financiranju, investiranju, itd.) do cjelokupnog gospodarstva (npr. konkurentnost izvoznih proizvoda države). Kretanje tečaja utječe na tempo gospodarskog razvoja zemlje te se uzima kao pokazatelj gospodarske snage i stabilnosti. Determinante utjecaja na kretanje deviznog tečaja predmet su istraživanja ovog rada. Cilj ovog rada je da se prvo teorijski pa zatim regresijskom analizom objasni te ispita utjecaj pojedine varijable na kretanje tečaja tri najvažnija svjetska valutna para - USD/EUR, USD/GBP i USD/JPY u periodu od 2002. do 2017. godine korištenjem podataka na mjesečnim razinama. Značajnost determinanti kretanja deviznog tečaja ne mora biti jednaka za sve valutne parove. Rezultati regresijske analize djelomično potvrđuju hipotezu H1 i H2. Postoji statistički značajna i pozitivna veza između kretanja kamatnih stopa i tečaja za sve valutne parove te postoji statistički značajna pozitivna veza između VIX indeksa straha i valutnog para USD/EUR. Također, djelomično se potvrdila H2 hipoteza da postoji statistički značajna i negativna veza između kretanja cijene nafte i tečaja valutnih parova USD/EUR i USD/GBP. Varijable indeks povjerenja potrošača (CCI), inflacija (CPI) i indeks industrijske proizvodnje u svim ocijenjenim modelima pokazale su se statistički neznačajnima.

KLJUČNE RIJEČI: devizni tečaj, kamatna stopa, inflacija, cijena nafte, VIX indeks, dohodak, indeks povjerenja potrošača

SUMMARY

The foreign exchange rate as an economic policy variable that is present in the entire economy and has multiple importance. The importance of the exchange rate can be observed through multiple levels, from an individual (e.g. foreign currency clause borrowing) through a multi-national company (remittance to a subsidiary, financing decisions, investment, etc.) to the entire economy (eg competitiveness of products). The movement of the exchange rate affects the pace of economic development of the country and is taken as an indicator of economic strength and stability. Determinants of exchange rate movement is the subject of this paper. The aim of this paper is firstly to explain theoretical and then conduct the regression analysis of the impact of a single variable on the exchange rate movements for the three most important currency pairs - USD / EUR, USD / GBP and USD / JPY in the period

between 2002. and 2017., using monthly data. The significance of the determinants of the exchange rate movement doesn't have to be the same for all currency pairs. Hypotheses H1 and H2 are partially confirmed by the results of the regression analysis. There is a statistically significant and positive link between interest rates and exchange rate movements for all currency pairs and also, there is a statistically significant positive correlation between the VIX index of fear and the USD / EUR currency pair. Furthermore, H2 hypothesis is also partially confirmed because results show that there is a statistically significant and negative link between the oil price movement and the USD / EUR and USD / GBP currency pairs. The consumer confidence index (CCI), inflation (CPI), and the index of industrial production are regressor variables that have shown statistically insignificant result in all tested models.

KEY WORDS: exchange rate, interest rate, inflation, crude oil price, VIX index, consumer confidence index